



HAL
open science

Apport de la télédétection satellitaire optique/thermique haute résolution à la prédiction de la sévérité des incendies de forêt en zone méditerranéenne française

Victor Penot

► To cite this version:

Victor Penot. Apport de la télédétection satellitaire optique/thermique haute résolution à la prédiction de la sévérité des incendies de forêt en zone méditerranéenne française. Sciences de la Terre. Université de Toulouse, 2025. Français. ⟨NNT : 2025TLSES059⟩. ⟨tel-05269538⟩

HAL Id: tel-05269538

<https://theses.hal.science/tel-05269538v1>

Submitted on 19 Sep 2025

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



HAL Authorization

Doctorat de l'Université de Toulouse

Apport de la teledetection satellitaire optique/thermique haute
résolution a la prédiction de la sévérité des incendies de forêt
en zone mediterraneenne française

Thèse présentée et soutenue, le 10 juin 2025 par
Victor PENOT

École doctorale

SDU2E - Sciences de l'Univers, de l'Environnement et de l'Espace

Spécialité

Surfaces et interfaces continentales, Hydrologie

Unité de recherche

CESBIO - Centre d'Etudes Spatiales de la BIOSphère

Thèse dirigée par

Olivier MERLIN

Composition du jury

Mme Valérie LE DANTEC, Présidente, Université de Toulouse

M. Albert OLIOSO, Rapporteur, INRAE Provence-Alpes-Côte-d'Azur

M. Jean-Baptiste FILIPPI, Rapporteur, CNRS Provence et Corse

Mme Mélanie ROCHOUX, Examinatrice, CERFACS

M. François PIMONT, Examineur, INRAE Provence-Alpes-Côte-d'Azur

M. Thomas OPITZ, Examineur, INRAE Provence-Alpes-Côte-d'Azur

M. Olivier MERLIN, Directeur de thèse, CNRS Occitanie Ouest

Remerciements

Tout d'abord, je remercie l'Université Toulouse 3 et l'IUT d'Auch pour m'avoir offert l'opportunité de mener à bien ce projet de recherche.

Je souhaite également adresser mes sincères remerciements à mon directeur de thèse, Olivier Merlin, pour son encadrement et ses conseils avisés. Sa rigueur intellectuelle et sa disponibilité ont été des atouts précieux pour la réussite de ce travail.

J'exprime aussi ma gratitude à l'INRAé-URFM et BioSP pour leur soutien scientifique tout au long de ce projet. Leur environnement de recherche dynamique et leurs conseils ont été la source d'idées fructueuses.

Je tiens à exprimer toute ma reconnaissance au personnel du CESBio pour leur soutien et leur collaboration. Leur expertise et leur aide ont été précieuses pour la réalisation de cette thèse.

Je n'oublie pas les équipes pédagogiques Génie Biologique et Hygiène Sécurité Environnement de l'IUT, qui m'ont autorisé à démarrer et à mener à bien ce projet.

Je remercie chaleureusement les équipes de l'ONF-DFCI et tous les personnels opérationnels pour leur collaboration.

Un grand merci à la société isartSAT à Barcelone et au personnel de l'Observatoire de l'Ebre à Roquetes. Leur hospitalité et leur aide ont rendu cette expérience encore plus enrichissante.

Enfin, je tiens à exprimer toute ma reconnaissance à ma famille.

Table des matières

Remerciements	2
Tableau des notations et acronymes	8
Résumé	12
Abstract	13
1 Introduction	14
1.1 Contexte	14
1.2 Prédiction de la sévérité potentielle des incendies de forêt	15
1.3 Contenu en eau du combustible vivant et stress hydrique	16
1.4 Questionnements scientifiques et objectifs de la thèse	18
2 État de l'art sur la prédiction de la sévérité potentielle des incendies et l'estimation du stress hydrique des forêts méditerranéennes à partir de données satellitaires optiques/thermiques	20
2.1 Mesure et estimation de la sévérité des incendies	20
2.2 Prédiction de la sévérité potentielle	26
2.3 Estimation du stress hydrique par télédétection optique/thermique	32
3 Apport des séries temporelles pré-feu de données satellitaires optiques et météorologiques pour la prédiction de la sévérité potentielle des incendies : application à la région méditerranéenne française	38
3.1 Introduction	38
3.2 Matériel et méthodes	39
3.3 Résultats et discussion de la prédiction du RBR potentiel	41
3.4 Résultats et discussion de la prédiction du NBR_{post} potentiel	44
3.5 Conclusion	47
3.6 Article associé : "Improved fire severity prediction using pre-fire remote sensing and meteorological time series : application to the French Mediterranean area"	48
4 Comparaison et analyse des performances de prédiction de quatre indices satellitaires de sévérité des incendies	94
4.1 Introduction	94
4.2 Matériel et méthodes	94
4.3 Résultats et discussion	95
4.4 Conclusion	96

4.5	Article associé : "Prediction of potential fire severity : which remotely sensed optical fire severity index should we use?"	98
5	Combinaison des données satellitaires optiques/thermiques Landsat et de hauteur de canopée pour estimer le stress hydrique et les flux turbulents dans les forêts méditerranéennes	118
5.1	Introduction	118
5.2	Matériel et méthodes	119
5.3	Résultats et discussion	121
5.4	Conclusion	124
5.5	Article associé : "Combining Landsat optical/thermal and LiDAR HD data to estimate turbulent fluxes over Mediterranean forests"	125
6	Mise en évidence des effets directionnels sur l'estimation du stress hydrique en forêt méditerranéenne à partir de données optiques/thermiques et proposition d'une correction phénoménologique	176
6.1	Introduction	176
6.2	Mise en évidence et correction de l'effet des ombres portées	177
6.3	Combinaison de l'approche $LST_{norm} - f_{vg}(T_{sd_{EB}})$ avec la correction de l'effet des ombres portées	184
6.4	Conclusion	188
6.5	Article associé : "Estimating the water deficit index of a Mediterranean holm oak forest from landsat optical/thermal data : a phenomenological correction for trees casting shadow effects"	191
7	Conclusion et perspectives	206
7.1	Contexte des travaux de thèse	206
7.2	Synthèse de l'étude	206
7.3	Limitations et perspectives	208
	Annexe	213
	Bibliographie	216

Table des figures

1.1	Schéma du gradient des potentiels hydriques dans le continuum vertical sol-plante-atmosphère d'un chêne vert isolé	18
2.1	Structure du <i>CBI</i> par strates forestières verticales	21
2.2	Exemple de placettes expertisées et valeurs de <i>CBI</i> calculées en Tunisie	21
2.3	Spectres pour différentes occupations du sol	22
2.4	Nuages de points illustrant la relation entre trois <i>FSI</i> et le <i>CBI</i>	24
2.5	Influence de la durée post-feu sur la régénération de la végétation	25
2.6	Exemple de feux de cimes et de surface	26
2.7	Le système <i>FWI</i>	30
2.8	Flux d'énergie disponibles ($Rn - G$) et dissipés ($H + LE$) en surface	33
2.9	Exemple d'espace $LST-f_{vg}$ et de son utilisation pour estimer <i>EF</i> en zone méditerranéenne	35
3.1	Carte de la zone d'étude et des incendies étudiés	39
3.2	Exemple d'unités spatiales de référence Feu-OS	40
3.3	Importance des variables sélectionnées par le modèle FLM en fonction du modèle pour le <i>RBR</i>	41
3.4	Boîtes à moustaches des performances de prédiction (R) du <i>RBR</i> sur les 10 prédictions du jeu de test en fonction du modèle	42
3.5	Fonctions de pondération β des modèles FLM pour le <i>RBR</i> et séries temporelles des prédicteurs <i>NDVI</i> , <i>DMC</i> et <i>DC</i>	43
3.6	Fonctions de lissage des prédicteurs sélectionnés par le modèle FLM pour le modèle LGAM du <i>RBR</i>	44
3.7	Boîtes à moustaches des performances de prédiction (R) du NBR_{post} sur les 10 prédictions du jeu de test en fonction du modèle	45
3.8	Fonctions de pondération β des modèles FLM pour le NBR_{post} et séries temporelles des prédicteurs <i>NDVI</i> et <i>DMC</i>	46
3.9	Fonctions de lissage des prédicteurs sélectionnés par le modèle FLM pour le modèle LGAM du NBR_{post}	46
4.1	Nuages de points de la performance de prédiction (R) (prédiction Basée sur le <i>FSI</i>) par rapport à la dépendance des <i>FSI</i> aux conditions avant l'incendie (P)	95
4.2	Boîtes à moustaches des performances de prédiction (R) par <i>FSI</i> et par méthode de prédiction.	96
5.1	Localisation des deux sites Eddy Covariance et des aires d'étude	119
5.2	Schéma résumant les approches $LST - f_{vg}$, $LST_{norm} - f_{vg}(Tsd_{context})$ et $LST_{norm} - f_{vg}(Tsd_{EB})$ et de leur évaluation	122

5.3	Nuage de points de H , LE et EF dérivés des données satellitaires vs H , LE et EF in situ pour l'ensemble des sites	123
6.1	Schéma de la méthodologie globale pour estimer et corriger EF de l'effet des ombres portées approximé par l'angle zénithal solaire (θ_S)	178
6.2	Erreur in situ $\Delta EF = EF_{sat} - EF_{insitu}$ vs θ_S pour les sites de Puechabon (haut) et Fontblanche (bas), et pour le JdD Complet (gauche) et le JdD Très Sec (droite).	180
6.3	Auto-Calibration du paramètre de correction a_{auto} sur le JdD Complet (a) et le JdD Très Sec (b) pour le site de Puechabon	180
6.4	Nuages de points des estimations et corrections de EF vs EF_{insitu} pour le site de Puechabon	181
6.5	Schéma de la méthodologie globale pour corriger EF_{sat} issue de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ de l'effet des ombres portées	185
6.6	Calibration Site et Auto-Calibration pour les sites de Puechabon et de Fontblanche	186
6.7	Nuage de points des estimations et corrections de EF pour les sites de Puechabon et Fontblanche vs EF dérivée des mesures in situ.	187
6.8	Nuage de points des flux dérivés des différentes méthodes d'estimation et correction des ombres portées vs les flux dérivés des mesures in situ pour le site de Puechabon	188
6.9	Nuage de points des flux dérivés des différentes méthodes d'estimation et correction des ombres portées vs les flux dérivés des mesures in situ pour le site de Fontblanche	189
7.1	Zone d'étude de Puechabon : altitude (a), pente a_{auto} de la Correction Auto-calibrée de EF dérivée de la méthode $LST - f_{vg}$ utilisant la LST dérivée des mesures satellitaires (b) et pente a_{auto} de la Correction Auto-calibrée de EF dérivée de la méthode $LST - f_{vg}$ utilisant la LST normalisée des effets topographiques (c)	211
7.2	Cartes de hc et pentes dérivées de hc pour Puechabon et Fontblanche respectivement	212
A.1	Nuage de points du $LFMC$ déduit des mesures sur le Réseau Hydrique entre 2015 et 2021 en fonction de EF estimée par la méthode $LST - f_{vg}$ (a) et corrigée de l'effet des ombres portées (b)	214
A.2	Nuage de points du $LFMC$ déduit des mesures sur le Réseau Hydrique entre 2015 et 2021 en fonction de EF estimée par la méthode $LST - f_{vg}$ (a) et corrigée de l'effet des ombres portées (b) par espèce	214
A.3	Nuage de points du $LFMC$ déduit des mesures sur le Réseau Hydrique entre 2015 et 2021 en fonction de EF estimée par la méthode $LST - f_{vg}$ (a) et de l'effet des ombres portées (b) par site.	215

Liste des tableaux

4.1	Performances de prédiction (R) de la prédiction Basée sur le FSI des FSI/FSI_{pre} par rapport aux FSI/FSI_{pre} déduits des mesures, et de la prédiction Basée sur le NBR_{post} des FSI dérivés des NBR_{post} prédits et des NBR_{pre} déduits des mesures, par rapport aux FSI déduits des mesures.	95
6.1	Métriques de précision de l'estimation de EF vs EF_{insitu} par type de correction et jeu de données de calibration pour le site de Puechabon	182
6.2	Métriques de précision de l'estimation de EF vs EF_{insitu} par type de correction, jeu de données de calibration et jeu de données d'évaluation pour le site de Puechabon	183

Tableau des Notations et Acronymes

Notation / Acronyme	Signification	Unité
a_{auto}	Pente de la Correction Auto-calibrée de l'effet des ombres portées ..	[-]
a_{site}	Pente de la Correction calibrée Site de l'effet des ombres portées ...	[-]
AFDRS	Australian Fire Danger Rating System	
ASTER	Advanced Spaceborne Thermal Emission Reflection Radiometer	
Auto-Calibration	Callibration sans données in situ du paramètre a_{auto}	
b_{auto}	Angle zenithal solaire pour lequel l'effet des ombres portées est négligeable (Correction Auto-calibrée)	°
b_{site}	Angle zenithal solaire pour lequel l'effet des ombres portées est négligeable (Correction calibrée Site)	°
Basée sur le FSI	Prédiction directe du FSI	
Basée sur le NBR_{post} ...	FSI déduit du NBR_{post} prédit et du NBR_{pre} dérivée des mesures satellitaires	
BRT	Boosted Regression Trees	
BUI	Indice de combustible disponible (Build-Up Index)	[-]
Calibration Site	Callibration avec données in situ des paramètres a_{site} et b_{site}	
CBI	Composite Burn Index	[-]
CFFDRS	Canadian Forest Fire Danger Rating System	
Correction Auto-calibrée ..	Correction des ombres portées issues de la Auto-Calibration	
Correction calibrée Site ...	Correction des ombres portées issues de la Calibration Site	
d_0	Hauteur de déplacement nulle	m
DC	Indice de sécheresse (Drought Code)	[-]
DMC	Indice d'Humus (Duff Moisture Code)	[-]
$dNBR$	Difference Normalized Burn Ratio	[-]
DOY	Jour de l'année (Day Of Year)	
EF	Fraction évaporative (Evaporative Fraction)	[-]
$EF_{c,auto}$	EF dérivée de la Correction calibrée Site	[-]
$EF_{c,site}$	EF dérivée de la Correction Auto-calibrée	[-]
EF_{insitu}	EF dérivée des mesures in situ	[-]
EF_{sat}	EF dérivée des données satellitaires	[-]
f_{vg}	Fraction de végétation verte (dans un pixel)	[-]
Feu-OS	Union des unités spatiales résultant de l'interrection entre un incendie et une classe d'occupation du sol	

<i>FFMC</i>	Indice de combustible léger (Fine Fuel Moisture Code)	[-]
FLM	Modèle linéaire fonctionnel (Funtionnal Linear Model)	
<i>FSI</i>	Indice(s) de sévérité issu(s) de la télédétection satellitaire (Fire Severity Index / Indices)	
<i>FSI_{post}</i>	<i>FSI</i> post-feu	
<i>FSI_{pre}</i>	<i>FSI</i> pré-feu	
<i>FWI</i>	Indice Feu Météo (Fire Weather Index)	[-]
<i>G</i>	Conduction dans le sol	W.m ⁻²
GAM	Modèle additif généralisé (Generalized Additive Model)	
<i>GeoCBI</i>	<i>Geo CBI</i>	[-]
<i>H</i>	Flux de chaleur sensible	W.m ⁻²
<i>H_{auto}</i>	<i>H</i> dérivé de <i>EF_{c,auto}</i>	W.m ⁻²
<i>H_{insitu}</i>	<i>H</i> dérivé des mesures in situ	W.m ⁻²
<i>H_{sat}</i>	<i>H</i> dérivé des mesures satellitaires et météorologiques	W.m ⁻²
<i>H_{site}</i>	<i>H</i> dérivé de <i>EF_{c,site}</i>	W.m ⁻²
<i>hc</i>	Hauteur de la canopée	m
<i>hc_{max}</i>	Hauteur de la canopée maximale permettant le couplage entre <i>LST</i> et flux turbulents	m
<i>Hc_{max}</i>	Médiane des <i>hc_{max}</i>	m
IFN	Inventaire Forestier National	
IGN	Institut Géographique National	
<i>ISI</i>	Indice de propagation initiale (Initial Spread Index)	[-]
JdD Complet	Jeu de données complet (toutes les dates de passage du/des satellites selectionnées)	
JdD Humide	Dates de passage du satellite pour lesquelles le cumul de pluie sur 15 jours est supérieur au quantile 0.5 du cumul de pluie sur la période d'étude	
JdD Sec	Dates de passage du satellite pour lesquelles le cumul de pluie sur 15 jours est inférieur au quantile 0.5 du cumul de pluie sur la période d'étude	
JdD Très Sec	Dates de passage du satellite pour lesquelles le cumul de pluie sur 15 jours est inférieur au quantile 0.25 du cumul de pluie sur la période d'étude	
<i>LAI</i>	Indice de surface foliaire (Leaf Area Index)	m ² .m ⁻²
<i>LE</i>	Flux de chaleur latente	W.m ⁻²
<i>LE_{auto}</i>	<i>LE</i> dérivé de <i>EF_{c,auto}</i>	W.m ⁻²
<i>LE_{insitu}</i>	<i>LE</i> dérivé des mesures in situ	W.m ⁻²
<i>LE_{sat}</i>	<i>LE</i> dérivé des mesures satellitaires et météorologiques	W.m ⁻²
<i>LE_{site}</i>	<i>LE</i> dérivé de <i>EF_{c,site}</i>	W.m ⁻²
<i>LFMC</i>	Contenu en eau du combustible vivant (Live Fuel Moisture Content)	kg.kg ⁻¹
LGAM	GAM avec variables temporelles décalées dans le temps (Lagged GAM)	
LiDAR	Light Detection And Ranging	
<i>LST</i>	Température de surface (Land Surface Temperature)	K
<i>LST_{norm}</i>	<i>LST</i> normalisée des effets de <i>hc</i>	K

$LST_{norm} - f_{vg}(Tsd_{context})$	Approche contextuelle d'estimation de EF dans l'espace $LST_{norm} - f_{vg}$ utilisant un bord sec plat estimé contextuellement ($Tsd_{context}$)	
$LST_{norm} - f_{vg}(Tsd_{EB})$	Approche contextuelle d'estimation de EF dans l'espace $LST_{norm} - f_{vg}$ utilisant un bord sec plat simulé par un modèle bilan d'énergie (Tsd_{EB})	
$LST - f_{vg}$	Approche contextuelle de référence pour estimer EF	
MODIS	MODerate-resolution Imaging Spectroradiometer	
NBR	Normalized Burn Ratio	[-]
NBR_{post}	Post-fire NBR	[-]
NBR_{pre}	Pre-fire NBR	[-]
$NDVI$	Normalized Difference Vegetation Index	[-]
NFDRS	National Fire Danger Rating System	
NIR	Proche InfraRouge (reflectance)	[-]
ONF	Office National des Forêts	
$PrecTot$	Précipitations cumulées durant l'automne (Octobre-Décembre) de l'année précédent l'incendie	mm
R	Coefficient de corrélation / Performance de prédiction	[-]
R^2	Coefficient de détermination	[-]
RBR	Relativized Burn Ratio	[-]
RBR_{pre}	RBR pré-feu	[-]
$RdNBR$	Relativized $dNBR$	[-]
$RdNBR_{pre}$	$RdNBR$ pré-feu	[-]
Rg	Rayonnement global / Flux courte longueur d'onde entrant	$W \cdot m^{-2}$
Rh	Humidité relative (Relative Humidity)	[-]
$RMSE$	Erreur quadratique moyenne (Root Mean Square Error)	
Rn	Flux net	$W \cdot m^{-2}$
SAFRAN	Système d'Analyse Fournissant des Renseignements Adaptés à la Ni- vologie	
$SAVI$	Soil-Adjusted Vegetation Index	[-]
SEBS	Surface Energy Balance System	
modèles de mélange	Modèle de mélange (Spectral Mixture Analysis)	
SPARSE	Soil Plant Atmosphere Remote Sensing Evapotranspiration	
STIC	Surface Temperature Initiated Closure	
$SWIR$	Moyen InfraRouge (réflectance)	[-]
$Tair$	Température de l'air	K
$TempMax$	Moyenne des maxima journaliers des $Tair$ estivales (juin-septembre) de l'année précédant l'incendie	
$\theta_{S,Min}$	Angle zénithal solaire minimum	°
θ_S	Angle zénithal solaire	°
TRISHNA	Thermal infraRed Imaging Satellite for High-resolution Natural re- source Assessment	
Tsd	Température de sol nu sec	K
$Tsd_{context}$	Température de sol nu sec estimée contextuellement	K
Tsd_{EB}	Température de sol nu sec simulée par un modèle bilan d'énergie	K
USA	Etats-Unis (United States of America)	
$VARI$	Visible Atmospherically Resistant Index	[-]

W_s	Vitesse du vent (Wind Speed)	$m.s^{-1}$
z_{0h}	Hauteur de rugosité pour la chaleur	m
z_{0m}	Hauteur de rugosité pour le moment	m

Résumé

Le changement climatique est une menace majeure pour les écosystèmes forestiers méditerranéens, en particulier du fait de l'augmentation du risque incendie. Pourtant, l'impact des incendies sur le milieu, ie la sévérité d'un incendie, reste encore peu étudié en région méditerranéenne française. Bien que les facteurs de variabilité soient bien connus (conditions météorologiques, état du combustible, topographie), les modèles de prédiction de la sévérité potentielle, principalement développés aux Etats-Unis, sont difficilement généralisables. L'hypothèse est que les prédictors utilisés actuellement sont incomplets et/ou trop incertains aux échelles spatiales considérées. Dans ce contexte de prévision de la sévérité potentielle des incendies en région méditerranéenne, cette thèse a pour objectif de 1) tester de nouveaux prédictors, et 2) développer de nouveaux indicateurs du stress hydrique des écosystèmes à partir des données satellitaires infrarouges thermiques à haute résolution spatiale. La première partie de la thèse s'intéresse à la prise en compte des dynamiques temporelles pré-feu de proxys de l'état du combustible dans les modèles de prédiction de la sévérité. Les séries temporelles pré-feu d'un indice de végétation issu de la télédétection (Sentinel-2, Landsat-7/8) et d'indices de sécheresse dérivés des données météorologiques sont extraites de 79 incendies estivaux (2016-2021). La prise en compte des dynamiques du combustible durant les 2 mois précédant l'incendie améliore la performance de prédiction de 32% par rapport au modèle de référence qui n'utilise que les données juste avant l'incendie. Une augmentation plus rapide que la moyenne de la sécheresse et une diminution plus rapide que la moyenne de la quantité de combustible vivant favorisent des sévérités plus élevées que la moyenne. La deuxième partie de la thèse s'intéresse à l'estimation du stress hydrique des forêts méditerranéennes à partir des données optiques/thermiques (Landsat-7/8/9) et des données LiDAR haute définition de l'IGN. La méthode contextuelle, couramment appliquée aux couverts relativement bas et de structure homogène, est adaptée de manière originale au cas des forêts. Les résultats sont évalués sur deux sites forestiers méditerranéens où des mesures par système eddy-covariance sont disponibles pendant 9 ans. La rugosité de surface (fonction de la hauteur de canopée) et les effets directionnels (ombres portées des arbres) sont identifiés comme des facteurs de variabilité de la température de surface (*LST*) Landsat, indépendamment du stress hydrique. Une méthode de normalisation de la *LST* des effets de hauteur de canopée et une correction de l'effet des ombres portées sont donc développées. Elles permettent de réduire le biais sur les estimations satellitaires et d'augmenter leur sensibilité au stress hydrique mesuré in situ de manière très significative par rapport à la méthode sans normalisation ni correction. Le stress hydrique dérivé des données thermiques pourrait être utilisé comme prédictor de la sévérité potentielle.

Abstract

Climate change is a major threat to Mediterranean forest ecosystems, particularly due to the increased risk of wildfires. However, the impact of fires on the environment, ie fire severity, remains poorly studied in the French Mediterranean region. Although the variability factors are well known (meteorological and fuel conditions, topography), the models predicting potential fire severity, that are mainly developed in the United States, are difficult to generalize. The assumption is that the predictors currently used are incomplete and/or too uncertain at the spatial scales considered. In this context of predicting potential fire severity in the Mediterranean region, this thesis aims to 1) test new predictors, and 2) develop new indicators of ecosystem hydric stress using high-resolution thermal infrared satellite data. The first part of the thesis focuses on the use of pre-fire temporal dynamics of fuel state proxies in fire severity prediction models. Pre-fire time series of a vegetation index derived from remote sensing (Sentinel-2, Landsat-7/8) and drought indices derived from meteorological data are extracted from 79 summer fires (2016-2021). Considering fuel dynamics during the 2 months preceding the fire improves prediction performance by 32% compared to the benchmark model that only uses data measured or computed just before the fire. Faster-than-average increases in drought and faster-than-average decreases in live fuel quantity favour higher-than-average severities. The second part of the thesis focuses on estimating hydric stress in Mediterranean forests using optical/thermal data (Landsat-7/8/9) and high-definition LiDAR data from IGN. The contextual method, commonly applied to relatively low and homogeneous land covers, is originally adapted to the case of forests. The results are evaluated on two Mediterranean forest sites where eddy-covariance system measurements are available for 9 years. Surface roughness (function of canopy height) and directional effects (tree casting shadows) are identified as variability factors of Landsat surface temperature (*LST*), independently of hydric stress. A method for normalizing *LST* for canopy height effects and correcting for cast shadows is developed. This method reduces bias in satellite estimates and significantly increases their sensitivity to in situ measured hydric stress compared to the method without normalization and correction. Hydric stress derived from thermal data could be used as a predictor of potential fire severity.

Chapitre 1

Introduction

1.1 Contexte

1.1.1 Les incendies de forêt en France

Les incendies sont l'aléa naturel historique le plus important affectant les forêts et les zones boisées sur le pourtour méditerranéen, devant les attaques par parasites, insectes, et autres événements météorologiques (Alexandrian et al., 1999). En France, ils affectent principalement la zone méditerranéenne et le massif forestier des Landes. En 2003, plus de 73 000 ha ont brûlés, notamment en zone méditerranéenne et plus récemment, en 2022, les incendies ont affecté plus de 30 000 hectares de forêt en Gironde. Ces événements d'ampleur sont appelés à se reproduire de plus en plus souvent dans le futur, du fait du changement climatique (Chatry et al., 2010; Fargeon, 2019; Pimont et al., 2023). Le risque est une saturation des services de lutte en cas de concomitance d'événements majeurs et un fort accroissement des coûts environnementaux et socio-économiques (Bacci et al., 2022). Il est donc important de comprendre et de quantifier les facteurs influençant les départs, la propagation et les conséquences des incendies afin d'en limiter le nombre ou l'ampleur.

Un incendie est la conséquence d'une mise à feu (ignition), de conditions météorologiques favorables à sa propagation et d'un combustible sec, abondant et continu (Chuvieco et al., 2023). En France, l'origine de la source d'ignition, est humaine dans 90% des cas (IGN-IFN, 2025). Les politiques de prévention, le développement d'une culture du risque et le changement des stratégies de lutte peuvent diminuer le nombre de départs de feu accidentels d'origine humaine (Fox et al., 2015) et changer la relation entre l'activité des feux (occurrence) et les conditions météorologiques (Ruffault and Mouillot, 2015). Par ailleurs, les conditions météorologiques à long et moyen termes affectent la disponibilité du combustible (croissance, siccité, mortalité) (González et al., 2018; Holz et al., 2012; Jin et al., 2014; Schlobohm and Brain, 2002), alors qu'à court terme elles favorisent le développement et la propagation des incendies (Canadian Forest Service Fire Danger Group, 1992; Cruz et al., 2015). Dans les prochaines décennies, le changement climatique pourrait être à l'origine de conditions météorologiques extrêmes (sécheresse, vague de chaleur, canicule) qui induiraient une plus grande disponibilité du combustible et des conditions de feu favorables à la propagation de grands incendies (Chatry et al., 2010; Fargeon, 2019; Pimont et al., 2023). Enfin, le combustible, via sa quantité (continuité, biomasse totale) et sa disponibilité (siccité, ratio mort/vivant) pilote aussi le comportement des incendies (Bradstock, 2010; Costes, 2021). Le dernier rapport de l'Institut Géographique National (IGN)-Inventaire Forestier National (IFN) (IGN-IFN, 2024) confirme une accélération de la mortalité des arbres en France (doublement en 10 ans : de $7.4 \text{ Mm}^3 \cdot \text{an}^{-1}$ en 2005-2013 à $15,2 \text{ Mm}^3 \cdot \text{an}^{-1}$ en 2014-2022, limitée en zone méditerranéenne). Ce phénomène pourrait augmenter la

quantité de combustible mort facilement mobilisable par l'incendie (Costes, 2021).

1.1.2 Estimation du risque incendie de forêt

Le risque incendie de forêt est la combinaison de l'occurrence des incendies et de leurs conséquences, qui sont définies par les impacts des incendies sur les environnements qu'ils affectent (Bachmann and Allgöwer, 2001). L'objectif des modèles de risque est d'estimer le risque pour une conséquence donnée. Dans le monde, trois grands modèles de risque sont utilisés. Les États-Unis (USA) utilisent le National Fire Danger Rating System (NFDRS) (Bradshaw et al., 1983; Schlobohm and Brain, 2002), le Canada utilise le Canadian Forest Fire Danger Rating System (CFFDRS) (Canadian Forest Service Fire Danger Group, 2021) et l'Australie, l'Australian Fire Danger Rating System (AFDRS) (Hollis et al., 2024). Ces modèles de risques reposent sur des modèles de combustibles, des données météorologiques et une modélisation semi-empirique des phases d'ignition et de propagation. Ces modèles sont aussi qualifiés de "météorologiques" car les entrées qui font varier le risque d'un jour à l'autre sont uniquement météorologiques. L'Europe et la France s'appuient sur des sous-systèmes et indices du CFFDRS pour estimer le risque incendie (DGSCGC, 2021; European Commission, 2025), en particulier le système Indice Feu Météo (*FWI*) (Van Wagner et al., 1987). En France, d'autres indices météorologiques comme le Niveau de Sécheresse de la Végétation Vivante et l'Indice de Propagation Sud-Est viennent compléter l'approche empirique d'estimation du risque en zone méditerranéenne (DGSCGC, 2021).

La valeur finale (indice *FWI*) du système *FWI* est une estimation de l'intensité d'un incendie (la puissance instantanée développée par le front de flamme). Le système *FWI* a été initialement calibré pour des conditions météorologiques rencontrées au Canada, et sur des essences forestières présentes dans ces milieux. Il n'est donc pas directement adapté au contexte méditerranéen. Aussi, l'étude et l'utilisation en France et en zone méditerranéenne du système *FWI* et de ses sous-indices en association avec d'autres données (eg occupation du sol, distance aux axes de circulation), reposent sur une relation statistique avec les occurrences des incendies et leurs aires (Barbero et al., 2019; Fox et al., 2018; Pimont et al., 2021; Ruffault and Mouillot, 2015). La modélisation des occurrences et des aires des incendies permet aux services de prévention et de lutte d'allouer spatialement et temporellement les moyens humains et matériels.

1.2 Prédiction de la sévérité potentielle des incendies de forêt

Keeley (2009) différencie deux définitions de la sévérité des feux de forêt : la "fire severity" et la "burn severity". Dans les deux cas, il s'agit d'une quantification de la consommation de la matière organique présente sur/sous le sol (humus, litière) et au-dessus du sol (strates aériennes de végétation). La "burn severity" est plutôt destinée aux mesures in situ (sévérité de terrain) alors que la "fire severity" peut être aussi utilisée pour les estimations (eg par télédétection satellitaire). La "fire severity" ou la "burn severity" sont traduites respectivement par estimation de la sévérité et sévérité de terrain.

Dans un contexte climatique où le bon fonctionnement des écosystèmes forestiers est mis à mal, peu de travaux sur les impacts des incendies sur les forêts autres que les surfaces brûlées (eg intensité, sévérité), ont été menés en zone méditerranéenne française. La mesure et la prédiction de l'intensité d'un incendie est principalement à destination des services de lutte et de prévention à court terme, mais peut aussi servir à créer des cartes de référence pour de plus longues périodes temporelles. L'intensité d'un incendie est très difficile et très complexe à mesurer in situ, dans des conditions réelles, en dehors d'incendies prescrits. Ces incendies ne sont quasiment jamais réalisés en Europe dans des conditions représentatives des conditions estivales. La mesure et la prédiction de la sévérité sont à destination des gestionnaires forestiers et des

services de prévention à moyen-long terme. La sévérité de terrain peut être mesurée ponctuellement ou estimée ex post sur de grandes surfaces.

La mesure et l'estimation de la sévérité ont pour objectif de mettre en place des mesures de gestion forestière post-incendie, afin de limiter les impacts sociétaux et environnementaux. A court terme, la sévérité peut être corrélée aux émissions de carbone par un incendie (Veraverbeke et al., 2015), au charriage de débris par des crues (Wells et al., 2019), à une altération de la qualité de l'eau (Shakesby et al., 2003) et à l'érosion des sols (Marion et al., 1991), a fortiori dans un contexte de changement climatique (Touma et al., 2022). La mesure ou l'estimation de la sévérité ont aussi pour objectif d'en comprendre les causes. Par exemple, Jain and Graham (2004) ont décrit la méthodologie pour étudier l'influence de la structure d'une forêt (eg densité des arbres, surface terrière, somme des diamètres des arbres) sur la sévérité d'un incendie à partir de mesures de terrain. Dans la description des résultats, Jain and Graham (2007) indiquent que la distance entre le sol et le houppier, la couverture forestière ou le diamètre des arbres sont autant de facteurs qui influencent la sévérité. Cependant, ils soulignent la limitation spatiale (Rocky Mountains) de leurs conclusions. Cette approche de terrain, limitée dans l'espace, ne permet pas le développement de modèle d'explication et de prédiction de la sévérité généralisables dans l'espace et dans le temps.

La télédétection satellitaire optique fournit des réponses aux limitations de l'approche de terrain car elle permet de couvrir de grandes surfaces. L'introduction de la télédétection s'est faite en trois temps. Tout d'abord elle a été utilisée pour estimer la sévérité de terrain (Key and Benson, 2005; Miller and Thode, 2007; White et al., 1996), ie dériver des proxys de sévérité de terrain à partir des mesures de réflectance (eg indice de sévérité). Cette phase validée, la télédétection a permis d'inclure une grande variété de conditions pré-incendies afin de mieux comprendre les facteurs influençant la sévérité, par une approche statistique (Parks et al., 2014b; Viedma et al., 2020). Les grands groupes de facteurs influençant la sévérité a priori d'un incendie sont alors identifiés : les conditions météorologiques à court, moyen et long terme, la topographie et le combustible (structure et disponibilité). Finalement, des modèles statistiques de prédiction de la sévérité potentielle – la sévérité qu'aurait un milieu s'il était affecté par un incendie – ont été développés sur la base de facteurs explicatifs (prédicteurs) (Fernández-García et al., 2022; Parks et al., 2018a). Cette approche permet à la fois, d'évaluer la mise en place de politiques de gestion forestières visant à limiter le niveau d'atteinte des forêts (Parks et al., 2018a; Price and Bradstock, 2012; Stephens et al., 2009), mais aussi d'établir une cartographie de référence de la sévérité potentielle à moyen terme, pouvant servir d'appui à la prise de décision.

1.3 Contenu en eau du combustible vivant et stress hydrique

Dans le domaine des feux de forêt, le statut hydrique de la végétation est défini par le contenu en eau du combustible vivant (*LFMC*) [$\text{kg}\cdot\text{kg}^{-1}$] (**Définition 1**). Le *LFMC* caractérise l'état de siccité (DGSCGC, 2021) et au final la disponibilité du combustible vivant au feu. Des valeurs élevées de *LFMC* étant un frein à la combustion (Costes, 2021), le *LFMC* est une grandeur importante pour modéliser la propagation des incendies et la sévérité. A ce jour, l'estimation du *LFMC* s'effectue par une modélisation statistique entre des mesures ponctuelles du *LFMC* (eg Réseau Hydrique sur le pourtour méditerranéen français, Martin-StPaul et al. (2018)) et des indices issus du système *FWI*, comme le l'indice de sécheresse (*DC*) (Pellizzaro et al., 2007). Ces indices météorologiques modélisent le forçage météorologique sur le combustible vivant, mais ils ne quantifie pas la réponse du combustible vivant à ce forçage, qui peut varier en fonction de l'espèce et de la disponibilité en eau dans le sol (état de surface) (Little et al., 2024; Vinodkumar et al., 2021). Leur utilisation requiert alors une calibration statistique site par site et espèce par espèce (Ruffault et al., 2018b). Par ailleurs, leur résolution spatiale est dépendante de la résolution

spatiale des données météorologiques (de l'ordre du kilomètre à la dizaine de kilomètres) qui est beaucoup plus importante que l'hétérogénéité des états de surfaces en zone méditerranéenne française.

Face à ces obstacles, une autre approche consiste à aborder le statut hydrique de la végétation à partir d'une autre grandeur, le stress hydrique. Le stress hydrique de la plante est une perturbation du fonctionnement physiologique normal de l'organisme (Limousin, 2009). En zone Méditerranéenne, deux mécanismes liés à la durée et à l'intensité du stress hydrique peuvent rendre les arbres vulnérables à la sécheresse. En cas de stress hydrique intense, la végétation risque le dessèchement. En cas de stress hydrique prolongé, la sécheresse peut mener à un épuisement des réserves carbonées de l'arbre. Dans cette étude, compte tenu de l'importance de la présence de l'eau dans le comportement des incendies, le stress hydrique de la plante sera abordé sous l'angle du dessèchement de la végétation.

Dans ce cadre, on dit que la plante subit un stress hydrique issu du couplage sol/plante/atmosphère, si la quantité d'eau extraite par les racines est inférieure à la quantité d'eau perdue par transpiration et déterminée par la demande évaporative de l'atmosphère. En effet, l'eau dans le sol peut être plus ou moins disponible pour la plante. L'état hydrique du sol étant couplé au fonctionnement de la plante, les potentiels hydriques Ψ (de la feuille, des racines, du sol, de l'atmosphère) et la conductance stomatique permettent de relier en série ces couplages sol-végétation-atmosphère (Jensen et al., 1991; Limousin, 2009).

Le stress hydrique de la plante est alors défini par sa mesure comme le potentiel hydrique de la feuille [Pa] (**Définition 2**). La circulation d'eau dans l'arbre s'effectue sous tension (potentiels négatifs) dans le sens des potentiels décroissants, du sol vers les feuilles (voir figure 1.1), afin que la transpiration foliaire soit compensée par le flux de sève brute entre les racines et les feuilles (Limousin, 2009). Au niveau des feuilles, les stomates régulent la transpiration (Berry et al., 2010). Si la demande atmosphérique est trop élevée (sécheresse atmosphérique : haute température de l'air, faible humidité relative) et/ou que le potentiel du sol est trop faible (sécheresse édaphique), les stomates limitent la transpiration. Ils peuvent se fermer (Jaleel et al., 2009), ce qui conduit à des potentiels foliaires (respectivement un stress hydrique) très négatifs (respectivement très élevé). A ce stade, la feuille ne transpire pas. Elle n'assure plus d'échanges gazeux avec l'atmosphère, ni ne dissipe de l'énergie par évaporation, ce qui induit une augmentation de sa température (Limousin, 2009). Les mesures de potentiel hydrique foliaire s'effectuent uniquement de façon ponctuelle par des méthodes destructives (chambre à pression) et sont donc limitées dans le temps et dans l'espace (Limousin et al., 2022). Ainsi des estimations spatialisées sur de grandes étendues (eg France) du stress hydrique de la plante ne sont pas disponibles à fine échelle spatiale.

Le stress hydrique de la surface inclut les composants sol et plante, via le bilan d'énergie de surface. L'équation du bilan d'énergie égalise la quantité d'énergie disponible avec l'énergie dissipée par les flux turbulents (flux de chaleur latente (LE) et flux de chaleur sensible (H)). LE est la quantité d'énergie dissipée par évapotranspiration de l'eau au sein du continuum sol-plante-atmosphère. Le facteur de stress hydrique [-] est défini (**Définition 3**) comme le complément dans 1 du ratio entre l'évapotranspiration effective et l'évapotranspiration potentielle (Anderson et al., 2011, 2007; Boulet et al., 2007), qui traduit la demande atmosphérique (Allen et al., 1998; Monteith, 1965; Penman and Keen, 1948). LE peut être mesuré par des lysimètres ou par des systèmes de mesure des fluctuations turbulentes ou Eddy Covariance (Eddy Covariance). Ces mesures sont généralement localisées dans l'espace et ne permettent pas d'estimer LE et le stress hydrique sur de grandes surfaces, en particulier dans des paysages hétérogènes. La télédétection spatiale dans le domaine optique/thermique fournit des données de température de surface (LST) sur de grandes étendues spatiales. Les mesures de LST sont représentatives de l'équilibre thermodynamique de la surface et peuvent ainsi être utilisées pour estimer LE par des modélisations de surface ou des approches semi-empiriques (Boulet et al., 2007; Mallick et al., 2014; Moran et al., 1994; Su, 2002).

Bien qu'il existe plusieurs définitions/approches du statut hydrique en fonction du domaine d'application, il existe des liens physiques entre elles. En cas de limitation d'accès à l'eau dans le sol et d'une forte




FIGURE 1.1 – Schéma du gradient des potentiels hydriques dans le continuum vertical sol-plante-atmosphère d'un chêne vert isolé. Les valeurs des potentiels hydriques (Ψ) sont données à titre indicatif des ordres de grandeur. D'après Rita Giuliani dans Limousin (2009)

demande atmosphérique, une importante régulation stomatique se met en place (faible potentiel hydrique foliaire, Définition 2). Le corollaire énergétique de la diminution de la transpiration au niveau de la feuille est une diminution de LE et donc une augmentation du stress hydrique, à conditions météorologiques égales (Définition 3). Par ailleurs, le potentiel hydrique foliaire (Définition 2) est lié au $LFMC$ de la feuille (Définition 1) via les courbes Pression-Volume (Nolan et al., 2020). Ainsi, les trois définitions/approches du statut hydrique présentées ici sont liées à l'échelle de la feuille.

De manière générale, le changement d'échelle, de la feuille à la canopée, puis de la canopée à la surface n'est pas trivial (Leuning et al., 1995; Nolan et al., 2022; Rambal et al., 2003). Il est communément fait l'hypothèse, valable au premier ordre, que le stress hydrique issu du bilan d'énergie de surface est représentatif des potentiels hydriques foliaire lorsque la couverture végétale est complète (Boulet et al., 2007; Mallick et al., 2015, 2014). Par ailleurs, le $LFMC$ foliaire est proche du $LFMC$ de la canopée si la canopée présente un faible rapport végétation morte sur végétation vivante (Nolan et al., 2020; Ruffault et al., 2023). Les trois approches sont donc cohérentes entre elles et physiquement liées à l'échelle de la surface sous certaines conditions. Enfin, seule la Définition 3 permet une estimation sur de grandes surfaces du stress hydrique qui soit fonction de l'état de surface, grâce aux mesures de la LST satellitaire. Aussi, dans toute la suite de cette étude, le stress hydrique est défini comme le stress hydrique de la surface représenté par le bilan d'énergie de surface.

1.4 Questionnements scientifiques et objectifs de la thèse

A ce jour, les modèles de prédiction de la sévérité potentielle atteignent des performances relativement faibles et sont difficilement généralisables à des milieux variés. L'hypothèse principale est que les prédicteurs utilisés dans les méthodes actuelles sont 1) insuffisants – les informations couramment disponibles sur l'état

du combustible et les conditions météorologiques sont incomplètes – et/ou 2) trop incertains aux échelles considérées – les proxys de *LFMC* issus de modèles météorologiques ont une résolution spatiale plus importante que l'échelle de variabilité des états de surface et ne sont pas sensibles aux états de surface.

Les données issues de la télédétection à haute résolution spatiale optique (10-100m) caractérisent la biomasse vivante mais pas l'état hydrique du combustible. Ainsi la prise en compte des dynamiques temporelles de ces données pourrait fournir une indication sur la partition entre combustible mort et combustible vivant. Les approches actuelles de prédiction de la sévérité n'intègrent pas ce type d'information puisqu'elles utilisent les données mesurées ou évaluées juste avant l'incendie. Par ailleurs, les données optiques/thermiques (*LST*) à haute résolution spatiale permettraient une meilleure estimation du stress hydrique que les indices de sécheresse issus des modèles météorologiques et classiquement utilisés dans les modèles de prédiction de la sévérité. Cependant, les méthodes d'estimation de référence du stress hydrique n'ont pas été testées sur les forêts méditerranéennes à ce jour.

Dans ce contexte, les questionnements de cette étude sont :

Comment améliorer les méthodes de prédiction de la sévérité potentielle des incendies à partir de la télédétection satellitaire à haute résolution spatiale ?

Comment estimer le stress hydrique des forêts méditerranéennes à partir des données satellitaires optiques/thermiques à haute résolution spatiale ?

Pour répondre à ces questions, plusieurs développements méthodologiques sont proposés. D'abord, une nouvelle approche de prédiction de la sévérité potentielle intègre pour la première fois l'historique temporel des prédicteurs de référence. Elle teste aussi différents indices satellitaires d'estimation de la sévérité. Ensuite, une méthode originale d'estimation du stress hydrique des écosystèmes méditerranéens est proposée à partir des données satellitaires optiques/thermiques. Il s'agit d'adapter les méthodes classiques existantes au cas complexe des forêts méditerranéennes, en prenant en compte les effets aérodynamiques (hauteur de canopée) et les effets directionnels (fraction d'ombre vue par le satellite) qui perturbent la relation entre *LST* et stress hydrique. En suivant cette présentation, le manuscrit est structuré en 7 Chapitres :

- Chapitre 1 : Introduction
- Chapitre 2 : État de l'art sur la prédiction de la sévérité potentielle des incendies et l'estimation du stress hydrique des forêts méditerranéennes à partir de données satellitaires optiques/thermiques
- Chapitre 3 : Apport des séries temporelles pré-feu de données satellitaires optiques et météorologiques pour la prédiction de la sévérité potentielle des incendies : application à la région méditerranéenne française
- Chapitre 4 : Comparaison et analyse des performances de prédiction de quatre indices satellitaires de sévérité des incendies
- Chapitre 5 : Combinaison des données satellitaires optiques/thermiques Landsat et de hauteur de canopée pour estimer le stress hydrique et les flux turbulents dans les forêts méditerranéennes
- Chapitre 6 : Mise en évidence des effets directionnels sur l'estimation du stress hydrique en forêt méditerranéenne à partir de données optiques/thermiques et proposition d'une correction phénoménologique
- Chapitre 7 : Conclusion et perspectives

Chapitre 2

État de l'art sur la prédiction de la sévérité potentielle des incendies et l'estimation du stress hydrique des forêts méditerranéennes à partir de données satellitaires optiques/thermiques

Dans ce Chapitre, une synthèse de l'état de l'art est réalisée. Elle définit les termes centraux, présente les méthodes ainsi que leurs limites, et justifie les choix qui perdurent dans toute cette étude. La Section 2.1 présente la mesure de la sévérité terrain des incendies et son estimation à partir des données satellitaires. Ensuite, la Section 2.2 définit la notion de prédiction, présente les principaux prédicteurs de la sévérité, ainsi que les limites actuellement rencontrées. Enfin la Section 2.3 décrit les différentes approches utilisées pour estimer le stress hydrique à partir de données satellitaires optiques/thermiques et leurs limites quand elles sont appliquées à des milieux similaires aux forêts méditerranéennes.

2.1 Mesure et estimation de la sévérité des incendies

2.1.1 Mesure de la sévérité de terrain

Les études menées sur la mesure opérationnelle de la sévérité de terrain des incendies depuis les années 1970, se sont concentrées sur les métriques qui quantifient la matière organique (biomasse) brûlée, à la fois dans et sur le sol (litière, caractéristiques du sol et des cendres) et dans les strates aériennes de la végétation (eg diamètre des branches, volume de canopée atteint par l'incendie, mortalité, etc) (Keeley, 2009; Miller et al., 2023). Dans le projet FIREMON (Fire Effects Monitoring and Inventory System : inventaire de la sévérité des incendies aux USA, basé sur des relevés de terrain et la télédétection satellitaire Landsat à 30m de résolution spatiale, Lutes et al. (2006)), Key and Benson (2005) a proposé un indice, le Composite Burn Index (*CBI*), qui intègre à lui seul différentes mesures de terrain censées intéresser les

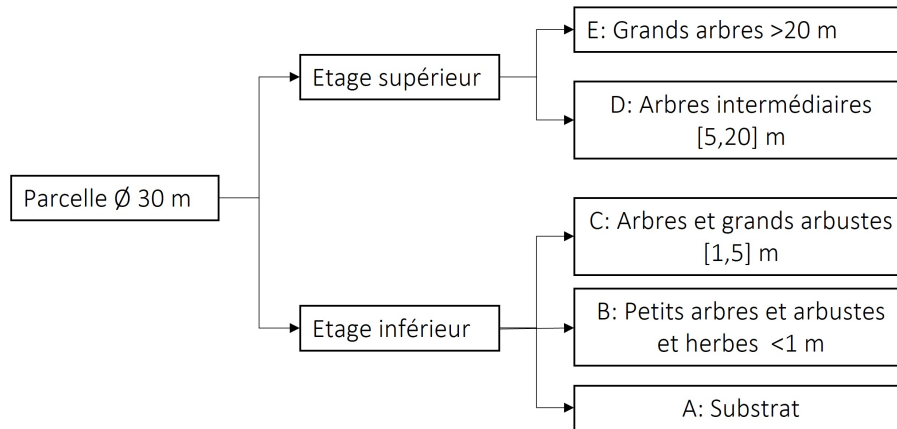


FIGURE 2.1 – Structure du *CBI* par strates forestières verticales d'après Miller et al. (2023)

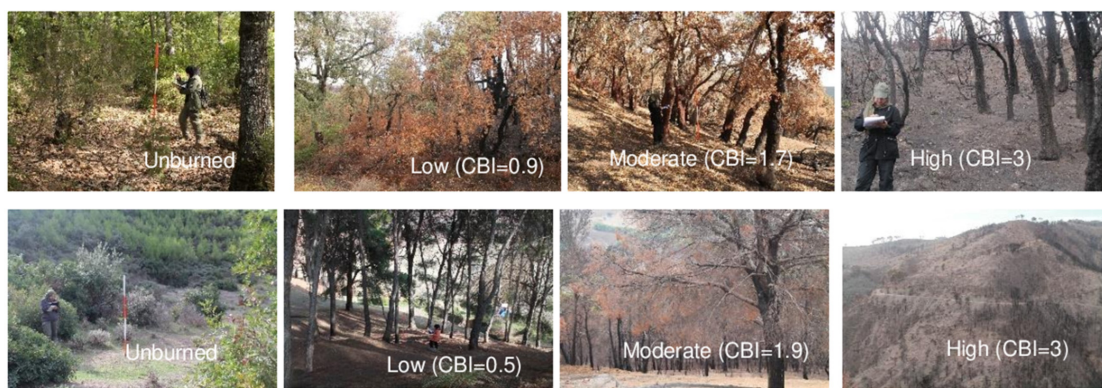


FIGURE 2.2 – Exemple de placettes expertisées et valeurs de *CBI* calculées en Tunisie d'après Amroussia et al. (2023)

gestionnaires forestiers a posteriori d'un incendie. En pratique, cet indice numérique sans unité, somme le niveau d'altération (de 0 – non brûlé – à 3 – combustion complète) de 5 strates verticales forestières (voir figure 2.1) sur une placette de 30 m de diamètre (dimension d'un pixel Landsat, voir figure 2.2). Le *CBI* est un proxy du niveau de combustion de l'ensemble des strates forestières constituant la placette. Il est possible d'avoir accès aux données de *CBI* aux USA via un portail dédié¹.

Cet indice a été modifié par la suite (*GeoCBI*, De Santis et al. (2010)). Le *GeoCBI* est pensé pour améliorer la sensibilité du *CBI* dans les milieux non-forestiers ou plus ouverts, en perfectionnant le lien physique avec les signatures spectrales visibles par le satellite (eg pondération des notes des strates par leur fraction dans la placette). En pratique, il doit limiter que des valeurs de *CBI* égales soient atteintes dans des conditions forestières différentes. Les auteurs valident leur approche avec l'utilisation de deux modèles de transfert radiatif, PROSPECT et GeoSail, qui leur permettent de simuler des spectres pour différents niveaux de sévérité et de conditions de terrain. Une récente synthèse bibliographique portant sur 62 études (Miller et al., 2023) a montré que ces deux indices sont utilisés dans plus de 90% des études (72% *CBI*, 20% *GeoCBI*).

1. <https://burnseverity.cr.usgs.gov/>

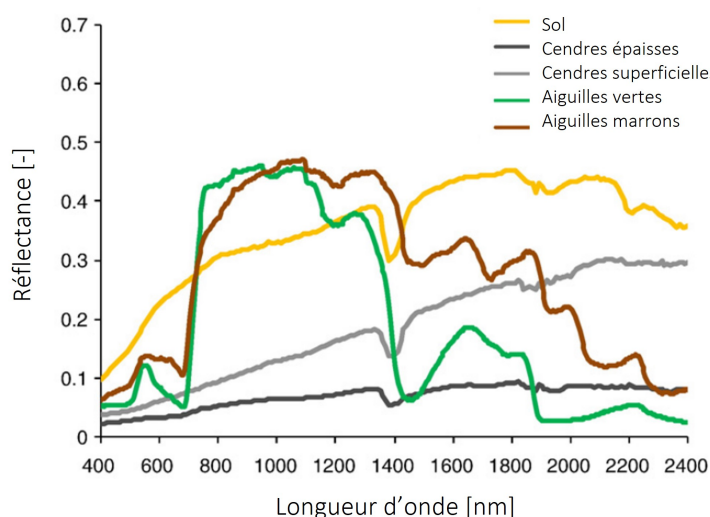


FIGURE 2.3 – Spectres pour différentes occupations du sol d’après De Santis et al. (2009)

2.1.2 Estimation de la sévérité de terrain à partir des données issues de la télédétection

La télédétection a permis d’étendre l’estimation de la sévérité sur de grandes surfaces, ce que ne permettent pas les mesures de terrain ponctuelles. La télédétection optique mesure une réflectance pour un intervalle de longueur d’onde (bande). La plupart des missions satellitaires (Sentinel-2, Landsat, Moderate-Resolution Imaging Spectroradiometer (MODIS)) fournissent plusieurs bandes spectrales entre le bleu et le moyen infra-rouge (*SWIR*). Chacune de ces bandes offre une sensibilité différente aux états de surface (voir figure 2.3). La caractérisation de l’état de surface post-incendie par la télédétection optique se base donc sur l’utilisation de ces bandes, soit de manière empirique, soit de manière physique.

Approches empiriques

La sévérité mesurée par *CBI* est un proxy de la consommation de biomasse vivante des différentes strates. La biomasse vivante étant quantifiable par télédétection satellitaire, plusieurs études ont évalué le lien statistique entre des indices de télédétection dédiés à l’étude de la végétation vivante et la sévérité de terrain (Key and Benson, 2005; Miller et al., 2023; Miller and Thode, 2007; Parks et al., 2014a). L’ensemble des indices dédiés à l’estimation de la sévérité sont communément appelés indices de sévérité des incendies (*FSI*). Les *FSI* combinent majoritairement le proche infrarouge (*NIR*) et le *SWIR* (Miller et al., 2023). La sensibilité de ces bandes aux impacts des incendies a été validée par des approches statistiques (Hoy et al., 2008; Miller and Yool, 2002) ou physiques (modèles de transfert radiatif, Chuvieco et al. (2006)). Le Normalized Burn Ratio (*NBR*) (López García and Caselles, 1991) combine le *NIR* et le *SWIR*. Avant l’incendie (NBR_{pre}), il estime la biomasse vivante pré-feu, et après l’incendie (NBR_{post}), il estime la biomasse vivante post-feu et la couverture en cendres. Les *FSI* différentiels ou bi-temporels, tel que le différence *NBR* ($dNBR$) (Key and Benson, 2005), le relativized $dNBR$ ($RdNBR$) (Miller and Thode, 2007) ou le Relativized Burn Ratio (*RBR*) (Parks et al., 2014a), établissent un lien statistique entre la sévérité de terrain et le changement relatif (*RBR*, $RdNBR$) ou absolu ($dNBR$) entre les dates antérieures à l’incendie (NBR_{pre}) et postérieures à l’incendie (NBR_{post}). Voici les expressions mathématiques de ces *FSI* :

$$NBR = \frac{(NIR - SWIR)}{(NIR + SWIR)} \quad (2.1)$$

$$dNBR = NBR_{pre} - NBR_{post} \quad (2.2)$$

$$RdNBR = RdNBR_{pre} - RdNBR_{post} = \frac{NBR_{pre}}{\sqrt{|NBR_{pre}|}} - \frac{NBR_{post}}{\sqrt{|NBR_{pre}|}} \quad (2.3)$$

si $NBR_{pre} \leq 0.001$ alors $NBR_{pre} = 0.001$

$$RBR = RBR_{pre} - RBR_{post} = \frac{NBR_{pre}}{1.001 + NBR_{pre}} - \frac{NBR_{post}}{1.001 + NBR_{pre}} \quad (2.4)$$

A l'origine, les *FSI* différentiels ont été introduits pour améliorer le contraste entre les zones brûlées et les zones non brûlées. Ils présentent un intervalle de variation plus important que les indices à date unique comme le NBR_{post} (Key and Benson, 2003), ce qui est particulièrement pertinent pour délimiter les zones brûlées (Hudak et al., 2007a). Il a été démontré que le $dNBR$ est fortement corrélé à la biomasse pré-feu (Birch et al., 2015; Fernández-García et al., 2022), en particulier à des niveaux de sévérité élevés (Escuin et al., 2008). Le $RdNBR$ et le RBR sont conçus pour être moins sensibles à la biomasse pré-feu (Miller and Thode, 2007; Parks et al., 2014a). A ce jour, il n'existe pas de consensus clair sur la prééminence d'un *FSI* par rapport à un autre pour estimer la sévérité de terrain (Epting et al., 2005; Escuin et al., 2008; Hudak et al., 2007b).

Certaines études se sont heurtées au manque de sensibilité des *FSI* pour évaluer les gradients de sévérité (Miller and Yool, 2002; Roy et al., 2006). Par ailleurs, l'approche empirique par *FSI* requiert une calibration par incendie (voir figure 2.4), possiblement du fait de l'autocorrélation spatiale (Collins et al., 2018) et de la confusion possible entre végétation morte et brûlée (Pfoch et al., 2023). Enfin les *FSI* pourraient manquer de bases physiques (Chuvieco et al., 2006; Collins et al., 2018), ce qui nuirait à leur généralisation.

Approches physiques

L'utilisation des modèles de mélange (modèles de mélange) ou des modèles de transfert radiatif repose sur la modélisation physique de la contribution de chacun des éléments composant une scène (un paysage) dans la signature spectrale qu'un satellite peut mesurer (Malhi et al., 2020). Il est nécessaire de connaître précisément les spectres des éléments composant la scène individuellement (voir figure 2.3). In fine, un spectre simulé correspondant à une sévérité de terrain connue, est associé avec un spectre mesuré et la sévérité de terrain en est déduite.

L'approche modèles de mélange considère qu'un spectre mesuré par un capteur est une combinaison linéaire des spectres de toutes les éléments composant une placette/pixel, sans notion de stratification verticale. Les proportions spectrales des éléments reflètent leur proportion surfacique dans le pixel étudié (Adams et al., 1995; Tompkins et al., 1997). L'approche modèles de mélange a été utilisée pour sa simplicité (Rogan and Franklin, 2001) ou encore sa capacité à mieux distinguer les éléments d'une scène (mort vs brûlé (Pfoch et al., 2023), ombres vs soleil (Quintano et al., 2013), fraction de cendres (Lentile et al., 2009)) que l'approche empirique. Cependant cette approche peut demander plus de dimensions (ie bandes) que celles proposées par les missions Sentinel-2 ou Landsat (eg hyperspectral (Quintano et al., 2013)). Leur supériorité par rapport à l'approche empirique reste discutée (Quintano et al., 2017; Smith et al., 2007).

Les modèles de transfert radiatif simulent les réflectances du bleu au *SWIR* pour différentes conditions post-incendie en prenant en compte la géométrie des différents éléments composant une scène et notamment leurs positions relatives (dessus, dessous) (Chuvieco et al., 2006). Les modèles de transfert radiatif

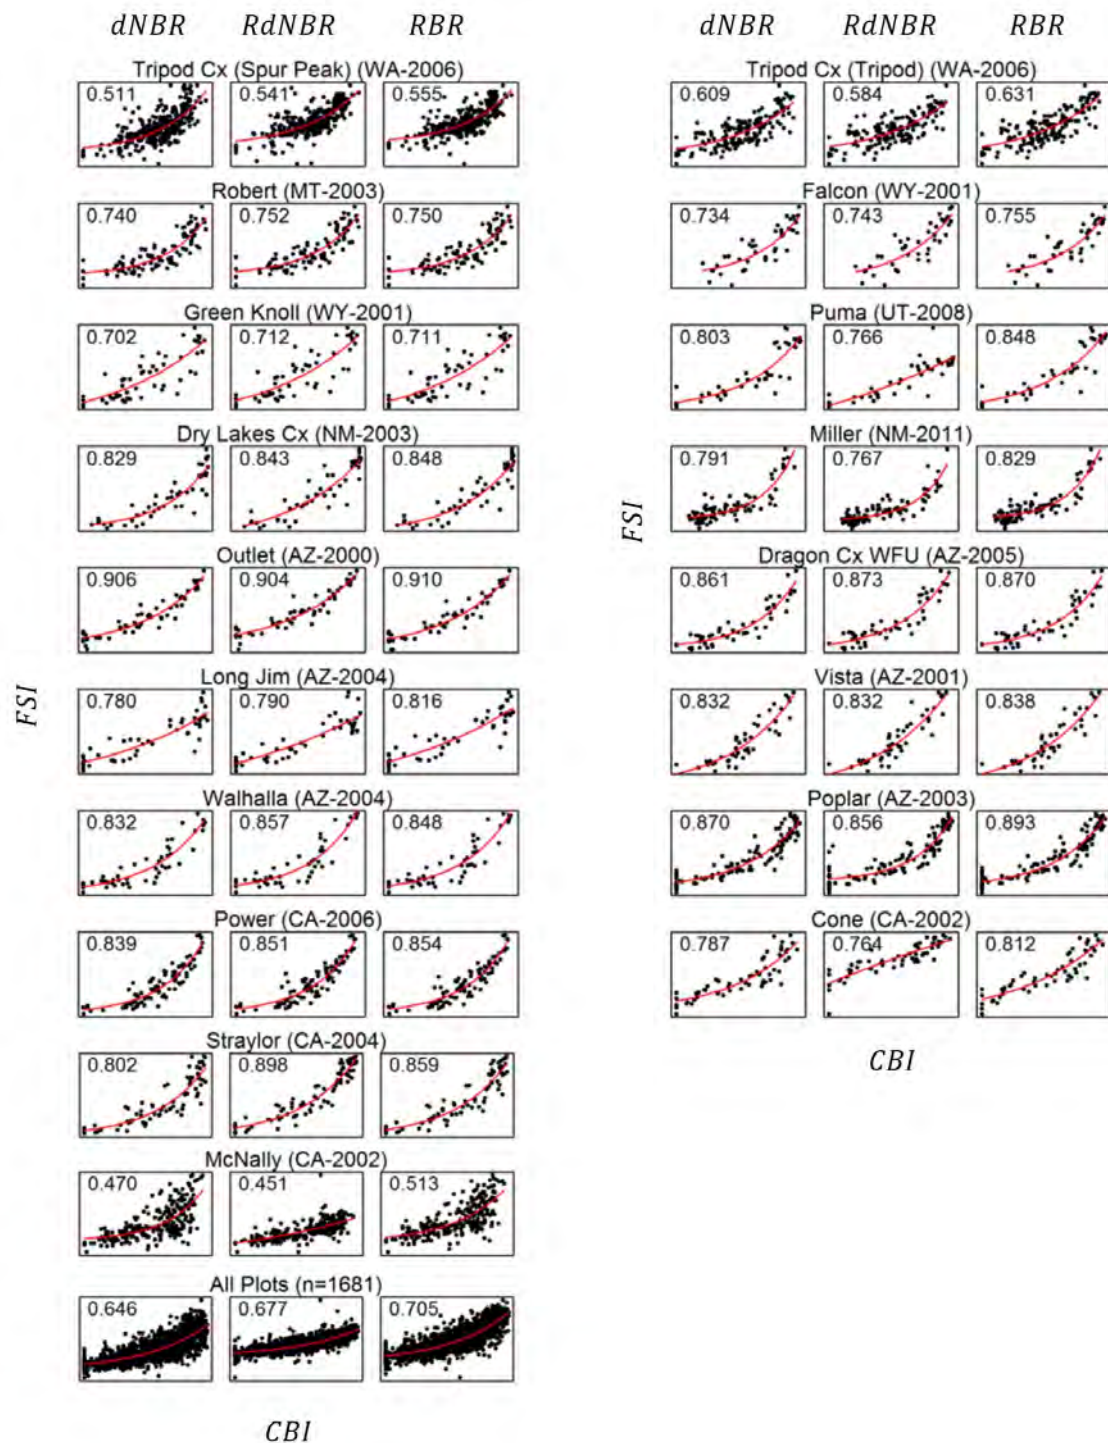


FIGURE 2.4 – Nuages de points illustrant la relation entre trois FSI (ordonnées) et le CBI (abscisses). L'abréviation de l'État (USA) et l'année dans lesquels l'incendie s'est produit sont indiqués entre parenthèses. Les lignes rouges représentent les ajustements non linéaires. Le coefficient de détermination (R^2) est indiqué pour chaque ajustement (d'après Parks et al. (2014a))

ont été utilisés pour étudier l'impact des ombres sur l'estimation de la sévérité (Disney et al., 2011) mais surtout pour inverser des indices de sévérité de terrain (eg CBI , $GeoCBI$) à partir de spectres (Chuvieco et al., 2007; De Santis and Chuvieco, 2007; De Santis et al., 2009; Yin et al., 2020). Une comparaison est souvent effectuée avec l'estimation empirique qui est la plupart du temps moins performante que l'estima-




FIGURE 2.5 – Influence de la durée post-feu sur la régénération de la végétation : 9 jours après un incendie (a) et 9 mois après un incendie au printemps (b)(photos : VP)

tion utilisant les modèles de transfert radiatif (De Santis and Chuvieco, 2007; Yin et al., 2020). Cependant les modèles de transfert radiatif s'avèrent complexes à mettre en œuvre (Chuvieco et al., 2007) et ils n'ont été testés que sur peu d'incendies (1-3 : De Santis et al. (2010); De Santis and Chuvieco (2007); De Santis et al. (2009) et 19 : Yin et al. (2020)).

Limites de la télédétection par satellite pour estimer la sévérité

La télédétection optique mesure les propriétés optiques d'un état de surface a posteriori d'un incendie. Quelle que soit l'approche d'estimation, la sévérité estimée par la télédétection optique peut être affectée par la diversité des situations rencontrées post-incendie (Chuvieco et al., 2006) incluant la durée depuis la fin de l'incendie, l'efficacité de la combustion, le type d'incendie (surface, cimes) et le type d'écosystème.

L'intervalle de temps entre la fin de l'incendie et le passage du satellite va principalement affecter la présence de cendres (érosion éolienne, hydraulique) (Hudak et al., 2007b) et le niveau de régénération des végétaux (variable selon l'écosystème). La présence de végétaux ayant une activité photosynthétique va affecter le signal et potentiellement entraîner une sous-estimation de la sévérité (voir figure 2.5).

L'efficacité de la combustion est l'interaction entre l'intensité d'un incendie, sa durée (combustion active et combustion lente), la quantité de combustible (vivant et mort) et son contenu en eau (Costes, 2021; Fearnside et al., 2001; Rogan and Yool, 2001). Plus la combustion de la végétation est complète plus la contribution des cendres est importante dans la signature spectrale d'un incendie. Cependant la végétation ainsi brûlée peut se confondre (d'un point de vue spectral) avec des surfaces non végétales (Rogan and Franklin, 2001).

Dans le cas d'incendie de surface sous couvert arboré, plus l'intensité du front de flamme est importante, plus il pourra se transformer en feu de cime (Canadian Forest Service Fire Danger Group, 1992). Un feu qui reste en surface sous la canopée a des impacts peu ou pas estimables par la télédétection optique (De Santis et al., 2010; Gale and Cary, 2022; Pereira et al., 2004; Rogan and Franklin, 2001), alors que s'il atteint la canopée, la surface brûlée est directement visible par le satellite (voir figure 2.6). Cependant un feu de surface peut aussi affecter le sol et donc le système racinaires (Zwolinski, 1990) et ainsi affecter à moyen ou long terme la canopée.

Les espèces et les écosystèmes présentent des caractéristiques qui les rendent plus ou moins sensibles aux incendies (Pausas et al., 2017), tant par leur intensité que par leur fréquence. En particulier lorsque la végétation est très clairsemée (zone semi-aride, landes/garrigues méditerranéennes clairsemées) la mesure du satellite est entravée par la contribution du sol et de la roche à la réflectance globale d'une scène (Rogan and Franklin, 2001).




FIGURE 2.6 – Exemple de feux de cimes et de surface (photos : VP)

Conclusion et choix de l'approche pour l'estimation de la sévérité

L'approche empirique utilisant les *FSI*, comme ceux dérivés du *NBR*, est largement plébiscitée et utilisée opérationnellement pour estimer la sévérité de terrain^{2 3}. Elle nécessite néanmoins d'avoir des mesures de terrain pour calibrer la relation *FSI*-sévérité de terrain. Les approches physiques, bien que prometteuses, restent trop complexes à mettre en œuvre pour une utilisation à grande échelle et leurs résultats sont mitigés. A fortiori, elles ne permettent pas de pallier les limites rencontrées avec les *FSI*. En particulier, l'obstruction par la canopée d'une surface brûlée est inhérente à l'utilisation de la télédétection optique. L'estimation de la sévérité par des *FSI* est donc utilisée dans cette étude, ie que les *FSI* sont considérés comme de bons estimateurs de la sévérité, malgré l'absence de données de terrain pour le vérifier.

2.2 Prédiction de la sévérité potentielle

2.2.1 Définition de la prédiction de la sévérité et évaluation des prédictions

Définitions de la prédiction

La prédiction de la sévérité revêt différentes définitions dans la bibliographie suivant les objectifs recherchés. Ces définitions sont détaillées ci-dessous.

Définition 1 : soit un ensemble de mesures de terrain ponctuelles de la sévérité et des *FSI*, partitionné en un jeu d'entraînement et un jeu de test. Un modèle statistique (eg linéaire, quadratique, polynomial, exponentiel) de la relation *FSI*-sévérité de terrain est calibré sur le jeu d'entraînement (voir figure 2.4). En supposant la relation statistique valable pour l'ensemble du/des incendies sur lesquels elle a été calibrée, la relation inverse (sévérité de terrain-*FSI*) permet de prédire et de spatialiser la sévérité de terrain après le/les incendies sur l'ensemble de la surface du/des incendies (García-Llamas et al., 2019; Gibson et al., 2020; Parks et al., 2019). La capacité de prédiction d'un *FSI* est définie comme la qualité statistique de la relation linéaire (eg corrélation *R*) entre les valeurs prédites de sévérité de terrain sur le jeu de test et les valeurs mesurées sur le terrain. Cette approche (calibration, test) est à la base de la comparaison des capacités d'estimation et de prédiction des *FSI* entre eux (Epting et al., 2005; Escuin et al., 2008;

2. <https://forest-fire.emergency.copernicus.eu/about-effis/technical-background/fire-severity>

3. <https://burnseverity.cr.usgs.gov/>

Fernández-Guisuraga et al., 2023; Hoy et al., 2008; Hudak et al., 2007b; Miller and Thode, 2007; Parks et al., 2014a; Soverel et al., 2010).

Définition 2 : soit un *FSI* et un jeu de variables mesurées ou calculées avant l'incendie et explicative de la sévérité (alors appelés prédicteurs). Un modèle statistique ou d'apprentissage machine du *FSI* est construit à partir des prédicteurs sur un jeu d'entraînement. Un autre jeu de données indépendant du jeu d'entraînement (jeu de test) est utilisé pour évaluer la performance de prédiction du modèle. La performance de prédiction d'un modèle est définie comme la corrélation (R) entre les prédictions d'un *FSI* réalisées sur le jeu de test et les valeurs du *FSI* dérivées des mesures satellitaires. L'objectif final est d'inférer les meilleurs prédicteurs, leur influence sur la variabilité du *FSI* et d'évaluer la capacité du modèle à se généraliser à d'autres lieux (Estes et al., 2017; Fang et al., 2018, 2015; Fernández-Guisuraga and Fernandes, 2023; Gale and Cary, 2022; Viedma et al., 2020; Wells et al., 2019). L'utilisation des *FSI* en lieu et place des mesures terrain de sévérité pour effectuer ce type d'étude, permet d'observer d'importants gradients de prédicteurs et de *FSI* afin de construire des modèles robustes. Ces conditions sont remplies par la grande disponibilité spatiale et temporelle des données satellitaires, au contraire des mesures terrain qui sont souvent peu nombreuses et ponctuelles. Si des mesures terrain de sévérité sont disponibles et que le *FSI* est choisi en conséquence, cela permet de prédire une sévérité de terrain potentielle. Sinon, une classification par niveau de sévérité de terrain peut être réalisée à partir des valeurs de *FSI*, en utilisant des classes de *FSI* déjà connues pour une large gamme de milieux (Costa-Saura et al., 2022; Epting et al., 2005; Escuin et al., 2008; Parks et al., 2018a,b; Taylor et al., 2021). Le *FSI* prédit peut aussi être considéré comme un bon descripteur des gradients de sévérité de terrain (Costa-Saura et al., 2022; Pascolini-Campbell et al., 2022).

Dans l'objectif d'établir une prédiction de la sévérité potentielle des incendies, ie la sévérité qu'aurait un incendie s'il survient dans un lieu non encore affecté, la Définition 2 est choisie pour la suite de cette étude.

Stratégie d'évaluation de la performance de prédiction

L'autocorrélation spatiale est définie comme la dépendance spatiale des prédicteurs et/ou de la sévérité estimée par *FSI*. Les incendies y sont particulièrement sensibles, rendant difficile l'inférence sur les causes de la variation de leur comportement (Bataineh et al., 2006; Odion et al., 2010). L'autocorrélation spatiale remet en cause la validation des modèles statistiques ou d'apprentissage machine lorsque le jeu de test est constitué de pixels proches de ceux du jeu d'entraînement. Cela peut mener à une surestimation de la qualité des modèles et/ou à une impossibilité à les extrapoler dans d'autres contextes (Gibson et al., 2020; Wells et al., 2019; Zacharakis and Tshrintzis, 2023).

Deux stratégies de construction du jeu de test existent afin d'évaluer la performance de prédiction du modèle construit tout en limitant l'autocorrélation spatiale. Une stratégie considère que l'évaluation peut être effectuée dans des pixels/positions non utilisés pour l'entraînement du modèle mais possiblement situés dans le/les mêmes incendies que ceux servant à l'entraînement. Les pixels/positions de test sont alors éloignés des pixels/positions d'entraînement d'une distance permettant de limiter l'autocorrélation spatiale. Afin d'estimer cette distance, l'indice de Moran est utilisé (Bataineh et al., 2006). Les distances obtenues sont très différentes selon les études : 45, 90 et 180 m (Kane et al., 2015), 800 m (Taylor et al., 2021), 1000 m (Pascolini-Campbell et al., 2022), 2000 m (Odion et al., 2010), 12000 m (Collins et al., 2014). Dans ce cadre, les performances de prédiction rapportées par la bibliographie sont souvent bonnes quel que soit le *FSI*. Par exemple les performances de prédiction observées sont $R \in [0.68, 0.92]$ (*dNBR*, Fang et al. (2015); Fernández-García et al. (2022); Viedma et al. (2020); Wells et al. (2019)), $R \in [0.78, 0.88]$ (*RdNBR*, Costa-Saura et al. (2022); Viedma et al. (2020)) et $R = 0.84$ (*RBR*, Viedma

et al. (2020)).

Une autre approche considère que les jeux de test et d'entraînement doivent être construits sur des incendies disjoints. Le jeu de test est ainsi indépendant spatialement et temporellement du jeu d'entraînement. Dans ce cadre, peu d'études existent et les résultats sont assez peu concluants. Fernández-García et al. (2022) atteignent une performance de prédiction $R = 0.49$ ($dNBR$). Dans le cas de prédictions de classes de sévérité, Parks et al. (2018a) atteignent une aire sous la courbe $AUC = 0.72$ (RBR à deux classes : $RBR < 0.298$ et $RBR > 0.298$) et Taylor et al. (2021) atteignent une erreur de prédiction égales à 36 % (faible sévérité), 68(%) (sévérité moyenne) et 71% (haute sévérité) ($RdNBR$ à trois classes d'après Miller and Thode (2007) : faible sévérité ($0.069 \leq RdNBR \leq 0.315$), sévérité moyenne ($0.315 < RdNBR \leq 0.640$) et haute sévérité ($RdNBR > 0.640$)).

La question de l'autocorrélation spatiale pourrait affecter l'ensemble d'un incendie en France car les incendies sont souvent petits. Elle questionne la capacité à choisir des prédicteurs et à décrire leur influence pour que ces inférences soient valables en tout lieu et en tout temps. Aussi, dans l'objectif de construire des modèles de prédiction de la sévérité potentielle (autre lieu), tout en assurant la robustesse des inférences établies sur la performance de prédiction et le comportement pré-feu des prédicteurs, l'évaluation des modèles est conduite sur un jeu de test composé d'incendies différents de ceux du jeu d'entraînement.

2.2.2 Prédicteurs de la sévérité

L'estimation de la sévérité des incendies à l'aide des FSI permet de rencontrer une grande variété de conditions avant et pendant les incendies. Trois groupes de prédicteurs ont été identifiés : les conditions météorologiques, le combustible et la topographie. Ils sont décrits dans les trois sections suivantes.

Les conditions météorologiques

Les conditions météorologiques à long, moyen et court termes se sont révélées être de bons prédicteurs de la sévérité des incendies (Birch et al., 2015; Fang et al., 2015). D'une part, les conditions horaires influencent la teneur en humidité des combustibles fins morts (Bradshaw et al., 1983; de Groot, 1987; Van Wagner et al., 1987) et le comportement du feu (Byram, 1959; Rothermel, 1972). D'autre part, les conditions à moyen et long termes influencent l'état hydrique (Bradshaw et al., 1983; Littell et al., 2016; Parks et al., 2014b; Taylor et al., 2021) et la production de biomasse des combustibles vivants (Parks et al., 2014b; Piedallu et al., 2019). En effet, l'alternance d'années humides et sèches favorise l'alternance entre forte croissance de la biomasse et forte disponibilité du combustible (González et al., 2018; Holz et al., 2012; Jin et al., 2014). Ces temporalités ont été intégrées dans de nombreux indices météorologiques spécifiques aux incendies, notamment ceux du système Indice Feu Météo (FWI , voir encadré "Le système FWI ").

Le système *FWI*

Extrait du système d'estimation du risque incendie CFFDRS, le système Indice Feu Météo (*FWI*) est utilisé opérationnellement en France et en Europe pour évaluer le risque incendie déduit des conditions météorologiques (il est aussi fait mention de danger météorologique). Le système *FWI* utilise uniquement les données météorologiques mesurées à midi (vitesse du vent (W_s), précipitations cumulées quotidiennes, température de l'air (T_{air}), humidité relative (Rh), voir figure 2.7 (a)). Le *FWI* est aussi l'indice final du système éponyme qui estime l'intensité du front de flamme (de Groot, 1987). Il a été calibré sur les forêts canadiennes de pin gris (*Pinus banksiana*, présent principalement en forêt Boréale et Amérique du nord), où il prend généralement des valeurs entre 0 et 30. En Europe et plus particulièrement France, il peut atteindre des valeurs bien supérieures à celle initialement observées (eg supérieures à 100) et n'a donc plus de sens physique. Dès lors, son utilisation opérationnelle repose sur sa corrélation aux surfaces et aux occurrences des incendies (Barbero et al., 2019; Pimont et al., 2021; Ruffault and Mouillot, 2015).

La structure du système *FWI* repose sur 3 sous-indices qui modélisent le contenu en eau de trois horizons du sol, liés à trois types de combustibles (voir figure 2.7 (a) et (b)). L'indice de combustible léger (Fine Fuel Moisture Code, $FFMC \in [0, 101]$) estime le contenu en eau de la litière, qui peut évoluer selon une durée caractéristique de 16 h (« timelag » : durée pour que le combustible perde exponentiellement 2/3 de son contenu en eau). Il est particulièrement bien adapté pour caractériser le contenu en eau du petit combustible mort qui s'équilibre rapidement avec les conditions météorologiques. Combiné avec la vitesse du vent il produit l'indice de propagation initiale (Initial Spread Index, $ISI \in [0, +\infty[$) qui donne une indication sur la vitesse de propagation d'un feu naissant dans la litière. L'indice d'humus (Duff Moisture Code, $DMC \in [0, +\infty[$, généralement inférieur à 400), estime le contenu en eau d'horizons plus profonds (5-10 cm) et a une durée caractéristique de 12 jours. Finalement, l'indice de sécheresse (Drought Code, $DC \in [0, +\infty[$, généralement inférieur à 1200) estime le contenu en eau d'horizons très profonds (supérieurs à 10 cm) et a une durée caractéristique de 52 jours. Ces deux indices sont combinés dans un indice cumulatif, l'indice de combustible disponible (Build-Up Index, $BUI \in [0, +\infty[$). Enfin le $FWI \in [0, +\infty[$ (indice) est calculé à partir de l' ISI et du BUI , par analogie avec la formule d'intensité de Byram (Byram, 1959). Tous ces indices sont des fonctions croissantes des conditions météorologiques favorables aux incendies.

Le combustible

Un des principaux prédicteurs de la sévérité est le combustible avant l'incendie. Trois caractéristiques du combustible sont intéressantes dans le cadre des feux de forêts : la structure tri-dimensionnelle, le ratio combustible mort/vivant, et le contenu en eau du combustible vivant.

La structure du combustible vivant (quantité, hauteur, port, continuité, etc) est un prédicteur important à relier directement au comportement de l'incendie et à la sévérité (Arroyo et al., 2008; Fox et al., 2015; Jin et al., 2014; Martin-Ducup et al., 2025). Une continuité horizontale va favoriser la propagation horizontale de l'incendie (Cruz et al., 2015), et une continuité verticale, va favoriser les feux de cimes (Pastor et al., 2003; Perrakis et al., 2023; US Forest Service, 2003). Cela justifie la réalisation des coupures de combustible et la réalisation des obligations légale de débroussaillage, avec évacuation des coupes, afin de limiter la propagation des incendies. La télédétection optique par satellite (Costa-Saura et al., 2022; Fernández-García et al., 2022), en particulier le Normalized Difference Vegetation Index ($NDVI$) (Parks et al., 2018a; Taylor et al., 2021), peut être utilisée pour quantifier la biomasse vivante (González-Alonso

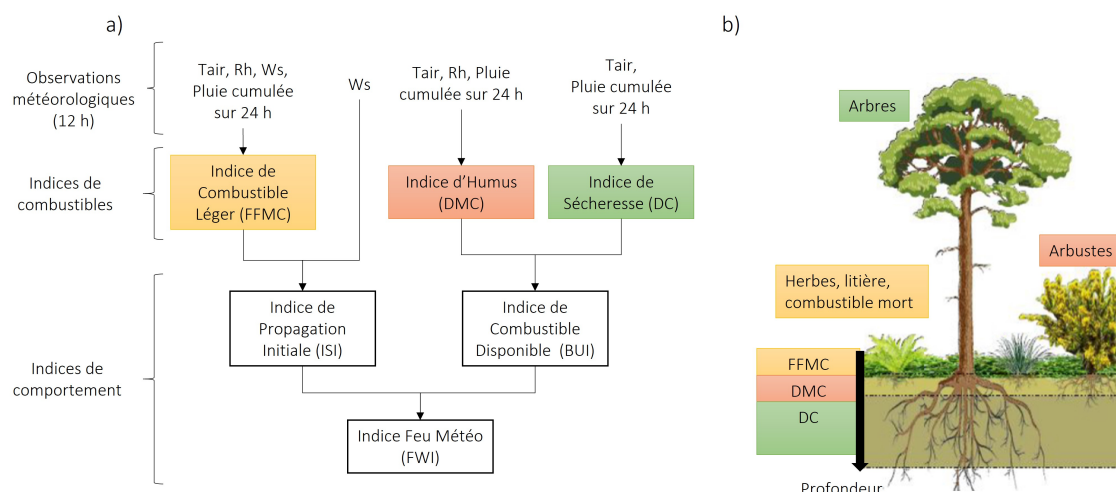


FIGURE 2.7 – Le système *FWI* : structure (a) et association entre profondeur dans le sol, profondeur du système racinaire et les indices de combustibles (c).

et al., 2006; Zhu and Liu, 2015). Comme toute mesure optique, l'utilisation du *NDVI* est limitée lorsque les strates verticales sont multiples. En effet, la strate supérieure occulte le signal des strates inférieures. De plus, les cartes de végétation ou d'occupation du sol peuvent donner des indications sur la distribution spatiale des espèces dominantes et la structure des combustibles. En particulier, les forêts ouvertes/fermées et les grandes classes forestières (caduque/persistant et conifères/feuillus/garrigues) ont montré de bonnes capacités explicatives et prédictives (Costa-Saura et al., 2022; Taylor et al., 2021; Viedma et al., 2020, 2014). Enfin, La disponibilité de plus en plus importante des données Light Detection And Ranging (LiDAR) sur de grandes surfaces, permettent de caractériser la structure verticale et horizontale du combustible (Gale et al., 2023; Labenski et al., 2023; Martin-Ducup et al., 2025; Viedma et al., 2020), sans pour autant distinguer le combustible mort du vivant. Ces données ne sont pas disponibles en France avant 2023.

Le ratio entre combustible mort et combustible vivant affecte la disponibilité du combustible au feu. En effet, la teneur en eau du combustible mort s'équilibre plus rapidement que celle du combustible vivant avec les conditions météorologiques (Jolly et al., 2024; Sharples et al., 2024). D'autre part l'eau contenue dans le combustible mort s'évapore plus facilement lors de la phase de chauffage que dans le combustible vivant (Costes, 2021). Le combustible mort est donc plus rapidement disponible pour le feu en cas de conditions météorologiques favorables (sécheresse atmosphérique : haute *Tair* et faible *Rh*). Il crée un contexte favorable aux incendies de hautes intensités, et promeut la mobilisation du combustible vivant (Ruthrof et al., 2016). Le ratio mort/vivant est intégré dans les modèles de risque et notamment dans les modèles de propagation (Cruz et al., 2015). Cependant la spatialisation du ratio mort/vivant reste un défi. La majorité des modèles de risque (NFDRS, CFFDRS) intègrent des modèles mathématiques empiriques de combustibles morts (courbes de sénescence). La télédétection spatiale n'a pas apporté jusqu'à présent de solution à la quantification de ce ratio dans tous les milieux. En effet le combustible mort est difficilement quantifiable par télédétection optique avant un incendie (Xu et al., 2014). Dans la strate herbacée qui joue un rôle important dans la propagation initiale des incendies, ce ratio est inféré par les variations de *NDVI* dans le temps (Chaivaranont et al., 2018; Duff et al., 2019; Newnham et al., 2011). Ces variations temporelles sont exploitées opérationnellement par le Fire Potential Index (Burgan et al., 1998) aux USA⁴ et au Mexique⁵ (Vega-Nieva et al., 2024). Le Fire Potential Index utilise un proxy (non calibré) du ratio mort/vivant : le *NDVI* est normalisé à l'échelle du pixel MODIS (250 m de résolution), par rapport aux

4. <https://www.usgs.gov/fire-danger-forecast/wildland-fire-potential-index-wfpi>

5. <https://forestales.ujed.mx/incendios2/>

valeurs minimale et maximale atteintes dans le passé sur ce même pixel. Cet indice est relié aux activités des incendies (Burgan et al., 1998; Vega-Nieva et al., 2024). Enfin, la combustion du combustible mort produit des cendres qui participent à la signature spectrale post-feu ce qui impacte l'estimation de la sévérité par *FSI* (Hudak et al., 2007b; Kokaly et al., 2007; Lewis et al., 2021).

Le contenu en eau du combustible vivant (*LFMC*) est une des variables clés dans les modèles de propagation des incendies (Cruz et al., 2015; Pimont et al., 2019) et de la sévérité des incendies. Il est quantifié sur le terrain de manière ponctuelle (Yebra et al., 2024). Ces mesures servent de bases à toutes les méthodes statistiques d'estimation du *LFMC*. Les indices météorologiques peuvent apporter des informations pertinentes et statistiquement significatives sur le *LFMC* (Jolly et al., 2024). Par exemple, le *DC* a été corrélé au *LFMC* d'arbustes (Pellizzaro et al., 2007; Ruffault et al., 2018b). Cependant ces indices météorologiques ne traduisent qu'une modélisation du forçage météorologique à faible résolution spatiale (supérieure au kilomètre) sur le combustible vivant. Puisqu'ils ne prennent pas en compte les états de surface (type de végétation, sols, etc), ils ne reflètent pas la réponse du combustible à ce forçage. La télédétection optique apporte des informations à fine échelle spatiale en lien avec les états de surface. Le *NDVI*, le Soil-Adjusted Vegetation Index (*SAVI*) ou le Visible Atmospherically Resistant Index (*VARI*) sont des proxy indirects de la teneur en eau des combustibles vivants (Chuvieco et al., 1999; García et al., 2020; Marino et al., 2020; Yebra et al., 2013). Ces indices sont sensibles aux conséquences physiologiques des variations du *LFMC*, ce qui peut être valable pour la strate herbacée ou les broussailles basses (Chuvieco et al., 2004; Yebra et al., 2008). Ces indices sont complétés par des indices utilisant le *SWIR* qui est sensible à la présence d'eau (Ceccato et al., 2002a,b; Yebra et al., 2008). Récemment, Yebra et al. (2018) ont développé une méthode pour spatialiser le *LFMC* en Australie à partir de données optiques MODIS. Une cartographie en ligne est disponible et mise à jour quotidiennement⁶. Concernant la télédétection thermique, seule la température de surface (*LST*) a directement été utilisée dans une approche statistique (Chuvieco et al., 2004; Cunill Camprubí et al., 2022). En particulier, Chuvieco et al. (2004) a montré une relation décroissante entre *LFMC* et *LST*. Enfin les données du domaine du micro-ondes (radar et radiomètre) ont été testées (Fan et al., 2018) et parfois couplées avec des données optiques (Rao et al., 2020). Cependant, quelles que soient les sources de données, toutes rencontrent des limites dans l'estimation des valeurs basses du *LFMC* (inférieures à 80-100%) qui sont critiques dans le comportement des incendies (Pimont et al., 2019).

La topographie

La topographie joue également un rôle important pour expliquer la sévérité. D'une part, elle est un moteur des incendies actifs, en particulier la pente qui interagit avec la vitesse, la direction du vent et le combustible (Byram, 1959; Rothermel, 1972; Viedma et al., 2020). Cependant, en raison de la différence des résolutions spatiales entre les produits de pente (10-20 m) et celle des données météorologiques (1-10 km), cet effet est difficile à prendre en compte en utilisant les produits et données courants. D'autre part, la topographie interagit avec le combustible vivant. La topographie influence le type de végétation, la disponibilité en eau et la production de biomasse (Dillon et al., 2011; Holden et al., 2009; Parks et al., 2018a).

Utilisation des prédicteurs dans les modèles

Les modèles utilisés pour expliquer ou prédire la sévérité sont pour la plupart de type statistique (Modèle additif généralisé *GAM* (Estes et al., 2017), Modèle linéaire généralisé (Lecina-Díaz et al., 2014)) ou d'apprentissage machine (Boosted Regression Trees *BRT* (Viedma et al., 2020), Random Forest (Taylor

6. <http://wenfo.org/afms>

et al., 2021)). Les prédicteurs variables dans le temps et dans l'espace sont généralement mesurés ou évalués juste avant l'incendie, ou intégrés dans des proxys qui résument ou cumulent l'information temporelle (eg z-score de *NDVI*, *DC*, Energy Release Component (Schlobohm and Brain, 2002)).

2.2.3 Conclusion

Les *FSI* largement expertisés et utilisés (*NBR_{post}*, *dNBR*, *RBR*, *RdNBR*) fournissent de bonnes estimations sur les gradients de sévérité de terrain malgré leurs limites. Le combustible, les conditions météorologiques et la topographie sont les trois grandes catégories de prédicteurs identifiées de la sévérité. L'évaluation des modèles de prédiction de la sévérité s'effectue sur des incendies spatialement indépendants des incendies d'entraînement. A ce jour, la prédiction de la sévérité potentielle reste un défi.

2.3 Estimation du stress hydrique par télédétection optique/thermique

2.3.1 Bilan d'énergie de surface

Le bilan d'énergie (bilan d'énergie) de surface égalise l'énergie disponible en surface (différence entre le flux net *Rn* et la conduction dans le sol *G*) avec l'énergie dissipée (*H + LE*) (voir figure 2.8). Le bilan d'énergie s'écrit (Jones and Rotenberg, 2011) :

$$Rn - G = LE + H \quad (2.5)$$

H est le flux de chaleur sensible (ou convection) et *LE* le flux de chaleur latente (ou évapotranspiration de la surface composée de la transpiration des plantes et l'évaporation du sol). La fraction évaporative (*EF*) est définie comme le ratio entre *LE* et l'énergie disponible en surface (Liu et al., 2020). *EF* quantifie la partition de l'énergie en surface entre *LE* et *H*. *EF* est relativement proche du facteur de stress hydrique décrit dans l'introduction (voir Section 1.3) (Boulet et al., 2007), en considérant que l'évapotranspiration potentielle de la surface (dérivée des données météorologiques et des propriétés du couvert, Allen et al. (1998)) est proche de l'énergie disponible. En effet, dans le cas où *LE* est égale à la totalité de l'énergie disponible en surface (*EF = 1*), ie en condition non limitée en énergie mais limitée en eau, la surface évapotranspire à la valeur maximale qu'il lui est possible d'atteindre (évapotranspiration potentielle). Pour une surface de végétation pleinement couvrante, *EF* (ou son complémentaire dans 1) est donc considérée comme une bonne approximation du facteur de stress hydrique. Aussi, dans toute la suite de cette étude, *EF* est considérée comme un proxy robuste du facteur de stress hydrique. Si toute l'énergie disponible est dissipée sous forme de chaleur sensible (*H*), alors *EF* est proche de zéro et le stress hydrique proche de 1. Inversement, si toute l'énergie disponible est dissipée sous forme d'évapotranspiration (*LE*) alors *EF* est proche de 1 et le stress hydrique est proche de zéro.

2.3.2 Missions satellitaires optiques/thermiques

Les mesures par Eddy Covariance in situ des flux et de *EF* sont difficiles à mettre en œuvre et localisées dans l'espace. La télédétection optique/thermique fournit des mesures de températures de surface (*LST*) qui permettent d'estimer *EF* sur de grandes étendues. A ce jour la missions MODIS a une fréquence de revisite supérieure à 1 fois par jour, au détriment de la résolution spatiale (1000 m). En zone méditerranéenne, les milieux naturels partagent de grandes interfaces avec les milieux urbanisés ou agricoles et sont situés dans les zones à la topographie accidentée. Ainsi, la résolution spatiale des capteurs satellitaires doit être adaptée à ces contraintes. Actuellement, les seules missions opérationnelles offrant



FIGURE 2.8 – Flux d'énergie disponibles ($Rn - G$) et dissipés ($H + LE$) en surface

une résolution spatiale adéquate sont les missions Landsat-8/9 (100 m de résolution spatiale) et Advanced Spaceborne Thermal Emission Reflection Radiometer (ASTER, 90 m de résolution spatiale). Cependant la fréquence de revisite n'est que de 8 jours et 16 jours respectivement. Pour pallier ce manque, plusieurs missions vont être lancées dans les années à venir. La mission Franco-Indienne Thermal infraRed Imaging Satellite for High-resolution Natural resource Assessment (TRISHNA) offrira dès 2025-2026 une fréquence de revisite de 3 jours à 60 m de résolution spatiale. Les missions Landsat offrent la possibilité, de par leur profondeur temporelle (à partir de 2013 en combinaison avec Landsat-7) et leur résolution spatiale (60-100 m), de préparer les futures missions afin que des produits (LE , EF) soient rapidement disponibles.

2.3.3 Méthodes d'estimation du stress hydrique utilisant les données optiques/thermiques

Deux approches – modèles bilan d'énergie (approches "single-pixel") et méthodes contextuelles – ont été développées pour estimer le stress hydrique (EF) et les flux turbulents (LE et H) à partir des données optiques/thermiques.

Modèles bilan d'énergie

Dans un modèle bilan d'énergie, la LST est utilisée comme un proxy de la température aérodynamique qui quantifie l'efficacité de l'échange de chaleur entre la surface de la Terre et l'atmosphère (Kustas et al., 2007). Quantitativement, la différence $LST - T_{air}$ est proportionnelle à H selon l'équation :

$$H = \rho C_p \frac{LST - T_{air}}{Rah} \quad (2.6)$$

avec ρ la densité de l'air, C_p la chaleur spécifique de l'air et Rah la résistance aérodynamique. Les modèles bilan d'énergie dérivent H comme la solution d'un système d'équations physiques (incluant l'équation (2.6)) dont les entrées sont des données météorologiques et la LST (Boulet et al., 2015; Su, 2002). LE est estimé comme le terme résiduel du bilan d'énergie. Les modèles bilan d'énergie fonctionnent à l'échelle

du pixel du satellite. Plusieurs modèles, avec des approches et des hypothèses différentes existent comme Soil Plant Atmosphere Remote Sensing Evapotranspiration (SPARSE, Boulet et al. (2015)), Surface Energy Balance System (SEBS, Su (2002)) ou Surface Temperature Initiated Closure (STIC, Mallick et al. (2014)). Pour une revue exhaustive des modèles bilan d'énergie voir Sebbar (2024). L'utilisation des modèles bilan d'énergie nécessite de définir un nombre plus ou moins important de paramètres difficiles à estimer ou à calibrer à l'échelle du pixel (Chirouze et al., 2014; Delogu et al., 2018). Par ailleurs, les modèles bilan d'énergie tendent à surestimer LE et sous estimer H dans les zones arides à semi-arides (Burchard-Levine et al., 2022; Gokmen et al., 2012; Gokool et al., 2020; Hu et al., 2023; Morillas et al., 2013; Van Der Kwast et al., 2009).

Méthodes contextuelles

Les méthodes contextuelles utilisent la relation spatiale semi-empirique entre la LST et un indice de végétation dérivé des mesures satellitaires pour estimer EF (Jiang and Islam, 1999; Moran et al., 1994; Wang et al., 2006). La fraction de végétation verte (f_{vg}) est souvent utilisée comme indice de végétation (Chirouze et al., 2014; Merlin, 2013) dans l'espace contextuel $LST-f_{vg}$ (voir figure 2.9, Carlson (2020); Jiang and Islam (1999); Moran et al. (1994); Tang et al. (2010); Venturini et al. (2004)). f_{vg} permet partitionner la fraction de sol et de végétation de façon à pondérer la relation entre EF et LST .

L'espace $LST-f_{vg}$ est délimité par une limite supérieure appelée "bord sec", et une limite inférieure, appelée "bord humide" (voir figure 2.9). Ces bords, supposés linéaires (Moran et al., 1994), définissent les valeurs extrêmes d'humidité, de $EF = 0$ pour un point sur le bord sec, à $EF = 1$ pour un point sur le bord humide. Ces bords sont soit estimés statistiquement à partir des conditions de surface observées dans une zone d'étude (Merlin, 2013; Tang et al., 2010), soit leurs extrémités (températures de sol nu sec (T_{sd}) et humide, températures de végétation sèche et humide) sont simulées par un modèle bilan d'énergie (Long and Singh, 2012; Long et al., 2012; Moran et al., 1994; Stefan et al., 2015; Sun et al., 2017). Dans les deux cas, le forçage météorologique est supposé uniforme dans la zone d'étude. De plus, l'utilisation de l'approche statistique pour estimer les bords, suppose que les conditions extrêmes (sèches à humides, du sol nu à végétation pleinement couvrante) sont présentes et observées à la résolution du capteur du satellite dans la zone d'étude (Merlin, 2013; Stisen et al., 2008). Cependant, puisque les conditions humides sont rares dans le contexte méditerranéen à la résolution spatiale des capteurs satellitaires durant la période des feux de forêt, les faibles valeurs de LST sont généralement trompeuses si elles sont interprétées comme représentatives de conditions humides. En supposant que la LST dans des conditions humides est proche de T_{air} ($H \ll LE$), le bord humide est fixé à T_{air} (voir figure 2.9) au moment du passage des satellites diurnes comme Landsat. Cette hypothèse a été faite dans de nombreuses études menées dans des environnements semi-arides (Amazirh et al., 2018; Long and Singh, 2012; Long et al., 2012; Merlin, 2013; Penot and Merlin, 2023; Sun et al., 2017; Zhang et al., 2014). Si les bords sont définis, EF s'estime comme le ratio entre la distance entre un point C de l'espace $LST-f_{vg}$ et le point A du bord sec de même f_{vg} et la distance entre le point B de même f_{vg} sur le bord humide et le point A (voir figure 2.9). On déduit alors les flux H et LE de cette estimation de EF pour le point C à partir d'un Rn estimé.

2.3.4 Sources d'erreurs dans l'estimation du stress hydrique à partir de la LST

Les effets aérodynamiques de la rugosité

La rugosité d'une surface caractérise l'influence de la géométrie tri-dimensionnelle des éléments la composant sur les mouvements fluides. La rugosité de la surface peut fortement influencer la dynamique des fluides et le transfert de chaleur dans les flux convectifs (Kadivar et al., 2021). A titre d'exemple, la

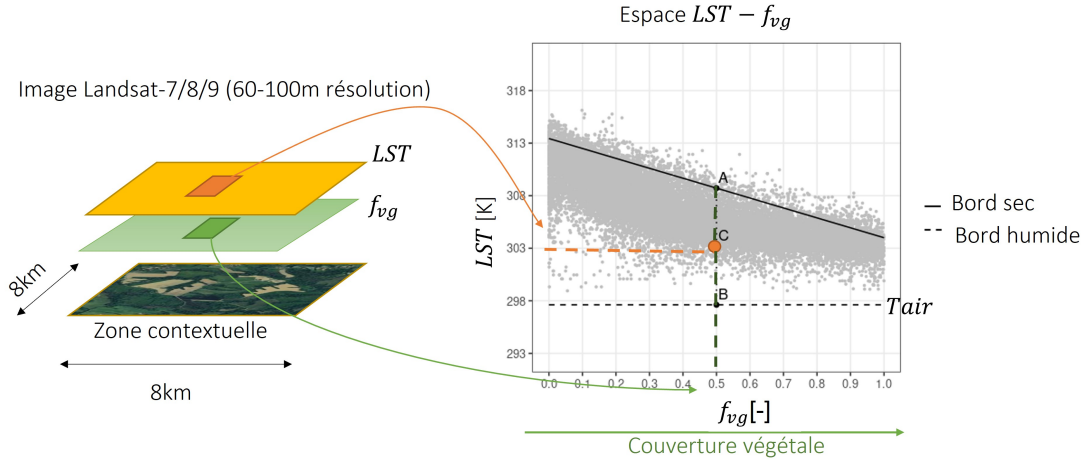


FIGURE 2.9 – Exemple d’espace $LST-f_{vg}$ et de son utilisation pour estimer EF en zone méditerranéenne. Le bord sec est décroissant : la température de sol nu sec (T_{sd}) est égale à 313 K ($f_{vg} = 0$) alors que la température de végétation humide est égale à 305 K ($f_{vg} = 1$). Le bord humide est plat et fixé à T_{air} . Une estimation de EF est égale à AC/AB .

végétation a généralement une rugosité supérieure à celle du sol nu, ne serait-ce que du fait de la hauteur du couvert. Cela explique, au premier ordre, la décroissance de la LST avec f_{vg} sur le bord sec de l’espace $LST - f_{vg}$ (voir figure 2.9) : plus la rugosité est importante moins la LST est élevée pour les mêmes conditions de stress hydrique (Sun et al., 2017). Cependant, les méthodes contextuelles classiques ne prennent pas explicitement en compte l’impact de la rugosité de surface sur la LST . Dans ces approches, la rugosité est supposée être liée par une relation strictement monotone avec l’indice de végétation utilisé (eg f_{vg}). En particulier, à une valeur de f_{vg} ne peut correspondre qu’une unique valeur de rugosité. Or dans les contextes naturels tels que les forêts méditerranéennes, différentes structures de canopée (différentes valeurs de rugosité) ont le même f_{vg} . Dès lors, les méthodes contextuelles classiques ne sont pas a priori adaptées aux aires d’études incluant des structures de canopée hétérogènes (Penot and Merlin, 2023).

La grande majorité des modèles bilan d’énergie basés sur la théorie de la similarité de Monin-Obukhov (eg SPARSE, SEBS) intègre la rugosité dans la résistance aérodynamique via des paramètres qui décrivent l’influence de la géométrie de surface sur les flux turbulents. Ces paramètres sont la hauteur de déplacement nul (d_0) et les hauteurs de rugosité pour la chaleur (z_{0h}) et le moment (z_{0m}) (Boulet et al., 2015; Su, 2002; Trebs et al., 2021). Dans cette approche physique, d_0 , z_{0m} et z_{0h} influencent particulièrement la résistance aérodynamique par leurs interactions avec la vitesse du vent et sont explicitement exprimés en fonction d’un nombre limité de caractéristiques de surface, possiblement fixe dans le temps, comme la hauteur de la canopée (hc), l’indice de surface foliaire (LAI) et l’indice de surface frontale (González-Dugo et al., 2021; Maurer et al., 2015; Shaw and Pereira, 1982; Tian et al., 2011; Trebs et al., 2021). Les sorties des modèles bilan d’énergie sont sensibles à l’expression de la rugosité dans les modèles de résistance aérodynamique et aux choix des valeurs des paramètres (Khan et al., 2021; Liu et al., 2016; Maurer et al., 2015; Meier et al., 2022). A titre d’illustration, avec la paramétrisation par défaut de SPARSE, soit $z_{0m} = z_{0h} = 0.13hc$ et $d_0 = 0.65hc$ (Trebs et al., 2021), une expression de la résistance aérodynamique en condition instable ($LST > T_{air}$) est (Choudhury et al., 1986) :

$$R_{ah} = \frac{1}{k^2 W_s (1 + Ri)^{0.75}} \ln \left(\frac{z - d_0}{z_{0m}} \right)^2 = \frac{1}{k^2 W_s (1 + Ri)^{0.75}} \ln \left(\frac{z - 0.65hc}{0.13hc} \right)^2 \quad (2.7)$$

avec k la constante de Von Karman, Ri le nombre de Richardson et z la hauteur des mesures de la vitesse du vent.

La complexité de la structure tridimensionnelle des forêts, qui peut évoluer à l'échelle infra-annuelle, rend complexes la modélisation de la rugosité et le choix des paramètres dans le temps et dans l'espace (Maurer et al., 2015; Trebs et al., 2021). La disponibilité et la couverture spatiale croissantes des données LiDAR haute définition permettent d'estimer des métriques de structure de la canopée (IGN, 2024; Potapov et al., 2021; Schwartz et al., 2024) dont la hauteur du couvert hc . Peu d'études ont utilisé ces données pour estimer les flux turbulents à partir des modèles bilan d'énergie en forêt (SEBS, Khan et al. (2021)) et aucune ne s'est en plus focalisée sur les milieux semi-arides. Certaines études ont montré les difficultés des modèles bilan d'énergie à estimer les flux turbulents sur forêt en conditions très sèches (Bartkowiak et al., 2024; Njuki et al., 2023; Trebs et al., 2021), telles que celles rencontrées en forêts méditerranéennes. La modélisation et la paramétrisation actuelles de la rugosité ne seraient pas adaptées pour tenir compte de la géométrie complexe des forêts dans ces conditions (Banerjee et al., 2017; Burchard-Levine et al., 2021; Trebs et al., 2021). Cela serait à l'origine de la sur-estimation de H et la sous-estimation de LE durant les périodes sèches (Njuki et al., 2023; Trebs et al., 2021).

Les effets directionnels à l'intérieur d'un pixel

La LST est une fonction des positions relatives du satellite et du soleil par rapport à la structure tri-dimensionnelle de la scène à l'intérieur d'un pixel. C'est ce que l'on appelle les effets directionnels (Michel et al., 2023) qui sont principalement dus à l'effet des ombres portées. Il est difficile de modéliser et d'évaluer avec précision l'impact des ombres portées dans des écosystèmes complexes en tout lieu (Prata et al., 1995). L'utilisation de modèles reproduisant les scènes réelles et simulant la LST (eg modèles de transfert radiatif) a permis de quantifier les impacts des effets directionnels sur la LST , par exemple sur des forêts et des cultures (Cao et al., 2019b; Guillevic et al., 2013, 2003; Luquet et al., 2004; Pinheiro et al., 2006). Les ombres portées au sein de la canopée et sur le sol ont une forte influence sur la LST (Prata et al., 1995) et donc sur les estimations du stress hydrique. En effet, les parties à l'ombre et au soleil composent chaque pixel satellitaire. Cependant, les informations sur le stress hydrique sont portées par les parties ensoleillées (LST très supérieure à T_{air} si le stress est important) alors que les parties à l'ombre ont une LST proche de T_{air} (stress hydrique apparent faible). La part d'ombres portées vue par le satellite peut alors induire une sous-estimation du stress hydrique.

A la résolution spatiale des satellites actuels et à venir, il n'existe pas de solution opérationnelle pour prendre en compte les effets directionnels dans l'estimation des flux turbulents et de EF . Les approches de modélisation des scènes réelles permettent de quantifier et de corriger l'effet des ombres portées sur la LST , et donc de mieux estimer LE et EF . Par exemple, dans le cadre des méthodes contextuelles, Luquet et al. (2004) ont suggéré de corriger la méthode $LST-f_{vg}$ pour prendre en compte les effets directionnels. Cette correction implique de redéfinir les bords humides et secs de l'espace $LST-f_{vg}$ en utilisant un modèle tridimensionnel exécuté pour chaque couple d'angles solaires et d'angles d'observation satellitaire. Cependant, ces approches requièrent qu'une maquette de la scène étudiée soit conçue, ce qui n'est pas réalisable sur de grandes surfaces. Certains modèles bilan d'énergie prennent en compte les effets directionnels en partitionnant le pixel étudié entre éléments à l'ombre et éléments au soleil (Mwangi et al., 2022). Ils n'ont pas été testés avec des mesures satellitaires de LST et ne sont pas à vocation opérationnelle. Enfin, certaines méthodes paramétriques permettent de corriger la LST des effets directionnels (Cao et al., 2019a,b). Ces méthodes dépendent d'un jeu de données d'entraînement (sur lesquels les effets directionnels sont connus) pour l'estimation de leurs paramètres, ce qui pourrait compromettre leur généralité du fait de la diversité des géométries de couverts en surface (Michel et al.,

2023).

2.3.5 Conclusion

De part leur approche physique, les modèles bilan d'énergie permettent de modéliser et donc de comprendre les phénomènes qui influencent l'estimation des flux turbulents et de EF à partir des mesures de LST . A ce jour, leur faiblesse réside dans la difficulté à les paramétrer à l'échelle du pixel sur des paysages complexes comme les forêts soumises à la sécheresse. Néanmoins, un modèle comme STIC s'affranchit explicitement de certains paramètres (eg z_{0m} , z_{0h} , d_0) et pourrait être un bon candidat dans le cadre d'une mise en œuvre opérationnelle. Les méthodes contextuelles proposent une approche semi-empirique dont l'apparente simplicité les rend adaptées à une utilisation opérationnelle, par exemple dans le cadre de la future mission TRISHNA (Gallego-Elvira et al., 2013). Aussi dans cette étude, dans l'objectif d'apporter aux futures missions un soutien si possible opérationnel, le choix s'est porté sur l'estimation du stress hydrique par les méthodes contextuelles.

Chapitre 3

Apport des séries temporelles pré-feu de données satellitaires optiques et météorologiques pour la prédiction de la sévérité potentielle des incendies : application à la région méditerranéenne française

3.1 Introduction

Les modèles de prédiction de la sévérité potentielle, estimée par FSI , ne fournissent pas de capacités de prédiction satisfaisantes à ce jour (Fernández-García et al., 2022; Parks et al., 2018a; Taylor et al., 2021; Wells et al., 2019). Leur approche repose sur l'utilisation de prédicteurs statiques dans le temps, généralement mesurés ou évalués juste avant l'incendie, ou résumant ou agrégeant l'information temporelle dans un indice (eg z-score de $NDVI$, DC). Les grandeurs influençant la sévérité (eg ratio combustible mort/vivant, $LFMC$) sont estimées par des proxys (indice météo, indices de télédétection optique) dont la valeur absolue ne reflète pas nécessairement les grandeurs estimées. Intégrer les dynamiques temporelles dans les modèles de prédiction peut être une plus-value intéressante pour améliorer les modèles de prédiction. Les dynamiques permettraient d'accéder à des informations non contenues dans une mesure ou une estimation ponctuelle dans le temps.

Dans ce Chapitre, deux FSI basés sur l'utilisation du NBR sont prédits : le RBR (Équation (2.4)) et le NBR_{post} (Équation (2.1)). Le premier est un FSI différentiel (ou bi-temporel), ie qu'il estime la sévérité de terrain en se basant sur une différence pré/post-feu du NBR . Il est utilisé dans des milieux hétérogènes incluant les milieux méditerranéens (McFarland et al., 2025; Parks et al., 2019). Il est une fonction croissante de la sévérité. Le second ne se base que sur des mesures post-feu des réflectances. Il est aussi utilisé en zone méditerranéenne (García-Llamas et al., 2019) et il est une fonction décroissante de la sévérité. La prédiction de deux FSI , différents dans leur formulation mathématiques mais indiquant tous les deux les gradients de sévérité, permet de comparer les dynamiques temporelles pré-feu des prédicteurs.

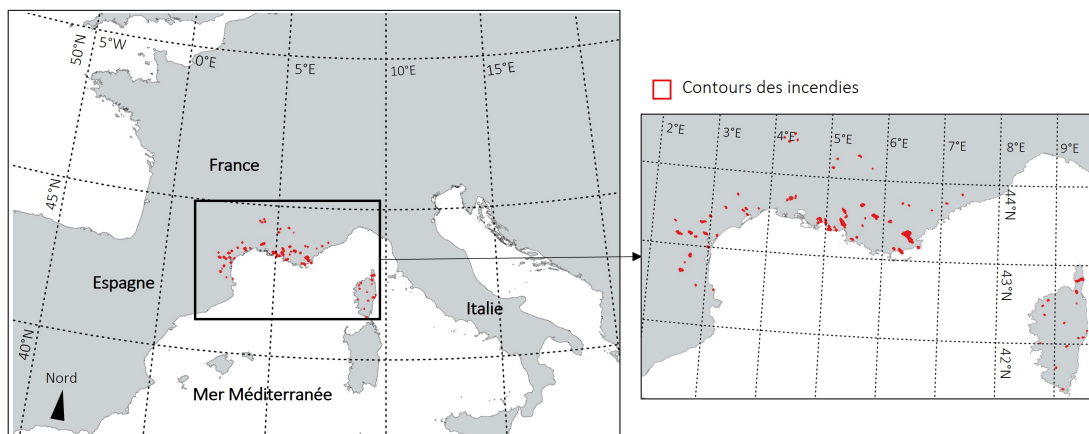


FIGURE 3.1 – Carte de la zone d'étude et des incendies étudiés

La Section 3.2 présente le matériel et les méthodes communs à la prédiction des deux *FSI*. La Section 3.3 présente la prédiction du *RBR*. L'ensemble de cette Section est basé sur un article qui présente tous les détails de l'étude (voir Section 3.6). La Section 3.4 présente la prédiction du NBR_{post} . Enfin, la Section 3.5 conclut ce Chapitre.

3.2 Matériel et méthodes

Les détails du matériel et des méthodes présentés par la suite sont disponibles dans l'article dédié à la prédiction du *RBR* potentiel disponible en Section 3.6.

3.2.1 Zone d'étude, incendies et occupation du sol

La zone d'étude recouvre l'ensemble du pourtour méditerranéen français (voir figure 3.1). La période d'étude s'étend de mai à octobre entre 2016 et 2021 (période estivale). Les contours d'incendies ont été fournis par l'Office National des Forêts (ONF). Les données d'occupation du sol, issues de la base de données forêt de l'Institut Géographique National (IGN), définissent dix classes d'occupation du sol dédiées aux forêts. Les surfaces résultantes de l'intersection entre les contours d'incendies et les contours des classes d'occupation des sols (Feu-OS) définissent l'échelle spatiale de référence pour cette étude. La figure 3.2 montre l'intersection entre le contour d'un incendie et trois classes d'occupation du sol. Trois individus statistiques (trois Feu-OS) sont ainsi créés. Seul les Feu-OS de plus de 13.5 ha sont retenus. Le jeu de donnée final recouvre ainsi 179 Feu-OS dans 79 incendies.

3.2.2 *FSI* et prédictors

L'ensemble des données de télédétection optique sont mesurées par les missions Sentinel-2 (10 et 20 m de résolution spatiale native – période minimale de revisite : 5 jours) et Landsat-7/8 (30 m de résolution spatiale native – période minimale de revisite : 8 jours) et moyennées par Feu-OS. Les données météorologiques proviennent du jeu de réanalyse Système d'Analyse Fournissant des Renseignements Adaptés à la Nivologie (SAFRAN, 8 km de résolution spatiale native) et les données de topographie sont fournies par l'IGN (25 m de résolution spatiale native). Uniquement les données pré/post-feu Sentinel-2 sont utilisées pour calculer les deux *FSI*.

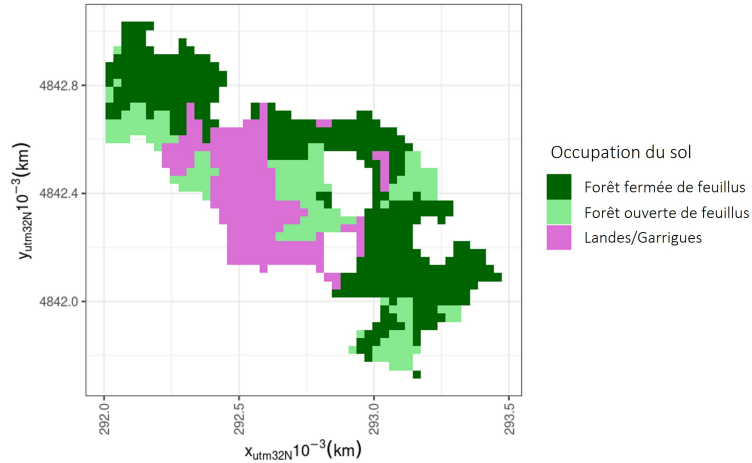


FIGURE 3.2 – Exemple d’unités spatiales de référence Feu-OS

Les prédictors dits "temporels", ie dont les séries temporelles pré-feu sont utilisées, sont le *NDVI*, issu de la télédétection satellite optique, et les indices météorologiques *DC* et *DMC*. La longueur maximale des séries temporelles est de 185 jours avant l’incendie. Les prédictors dits "statiques", ie utilisés directement comme scalaires, sont l’*ISI* (jour de l’incendie), le jour de l’incendie dans l’année (*DOY*), les précipitations cumulées durant l’automne (Octobre-Décembre) de l’année précédant l’incendie (*PrecTot*), la moyenne des maxima journaliers des *Tair* estivales (juin-septembre) de l’année précédant l’incendie (*TempMax*), l’altitude et la pente moyennes du Feu-OS, et la longitude et la latitude du barycentre du Feu-OS. Si nécessaire ces prédictors sont moyennés par Feu-OS.

3.2.3 Modèles développés

Trois modèles statistiques sont développés pour évaluer l’apport des séries temporelles. Le modèle de référence est un GAM. Il prend en entrée les prédictors évalués ou mesurés immédiatement avant l’incendie. Un deuxième modèle LGAM est identique au GAM, à ceci qu’il prend en entrée les valeurs ponctuelles et décalées dans le temps avant l’incendie des prédictors temporels (décalage dans le temps τ). Enfin le troisième modèle, un modèle linéaire fonctionnel (FLM), prend en entrée les séries temporelles des prédictors temporels et les prédictors statiques (profondeur des séries temporelles δ).

La procédure d’évaluation des modèles repose sur une validation croisée sur 10 sous échantillons et répétée 10 fois. Dans cette approche, tous les Feu-OS d’un incendie sont soit dans le jeu d’entraînement, soit dans le jeu de test. Ainsi chaque *FSI* d’un Feu-OS est prédit exactement 10 fois à partir de modèles entraînés sur des jeux d’entraînement spatialement indépendants du Feu-OS. Les *FSI* prédits sont comparés aux valeurs des *FSI* issus des mesures satellites.

Une phase d’optimisation recherche quelle est la profondeur temporelle δ_{opt} (respectivement le décalage temporel τ_{opt}) des séries temporelles dans l’intervalle $[-185; -15]$ jours qui permet d’obtenir la meilleure performance de prédiction pour le modèle FLM (respectivement LGAM). En même temps, les meilleurs prédictors sont sélectionnés. Finalement l’importance de chaque prédictor est calculée pour chacun des trois modèles développés.

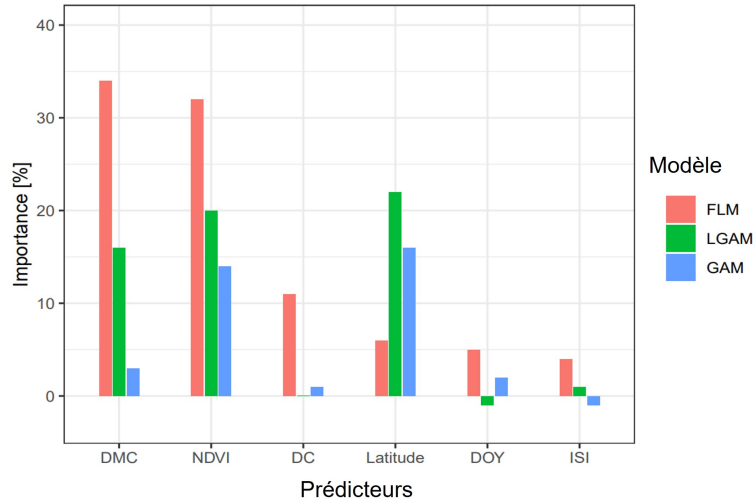


FIGURE 3.3 – Importance des variables sélectionnées par le modèle FLM en fonction du modèle pour le *RBR*

3.3 Résultats et discussion de la prédiction du *RBR* potentiel

Les détails des résultats et leur analyse sont disponibles dans l'article dédié à la prédiction du *RBR* potentiel disponible en Section 3.6.

3.3.1 Résultats de l'optimisation des modèles et performance de prédiction

Les prédicteurs optimaux sélectionnés par le modèle FLM sont par ordre décroissant d'importance (entre parenthèse pour le modèle FLM) : le *DMC* (34%), le *NDVI* (32%), le *DC* (11%), la latitude (6 %), le *DOY* (5%) et l'*ISI* (4%). Le modèle FLM donne beaucoup d'importance à des prédicteurs temporels caractérisant les dynamiques du combustible (*NDVI*) et le forçage météorologique (*DMC*, *DC*). Comme le montre la figure 3.3, l'importance des variables est différente suivant le modèle considéré. Les modèles LGAM et GAM donnent la plus grande importance à la latitude qui est une variable traduisant un effet spatial, plutôt qu'un effet biophysique.

La profondeur temporelle optimale est $\delta_{opt} = -65$ jours pour le modèle FLM, alors que le décalage temporel optimal pour le modèle LGAM est $\tau_{opt} = -25$ jours. La comparaison des performances de prédiction entre les modèles est sans appel. La figure 3.4 montre les performances de prédiction (R). La prise en compte de variables temporelles décalées dans le temps (modèle LGAM) permet d'améliorer les qualités de prédictions du modèle GAM. Par ailleurs la prise en compte des séries temporelles dans le modèle FLM permet d'atteindre des performances de prédiction non atteintes par les modèles LGAM et GAM. Ce niveau de performance de prédiction n'a pas été atteint dans les autres études ($R = 0.49$ pour le *dNBR*, Fernández-García et al. (2022)), même si la comparaison est limitée compte-tenu de la prédiction d'autres *FSI* ou de classes de sévérité (Parks et al., 2018a; Taylor et al., 2021).

3.3.2 Impacts des prédicteurs temporels

Les résultats des modèles FLM, LGAM et GAM permettent une meilleure compréhension des dynamiques du *DMC* avant un incendie. Le modèle FLM montre que les hautes sévérités (respectivement faibles sévérités), ie supérieures (respectivement inférieures) à la moyenne des *RBR*, sont atteintes si le *DMC* augmente (respectivement diminue) plus rapidement que la moyenne des *DMC* et que le *DMC*

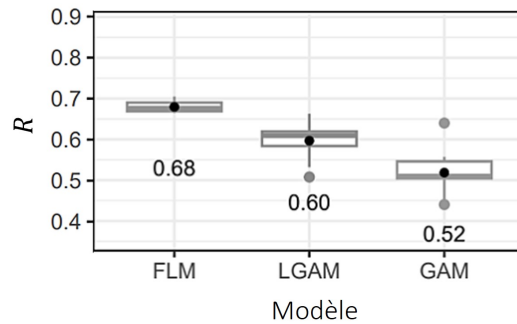


FIGURE 3.4 – Boîtes à moustaches des performances de prédiction (R) du RBR sur les 10 prédictions du jeu de test en fonction du modèle. La valeur numérique et le point noir correspondent à la moyenne des performances de prédiction.

est inférieur (respectivement supérieur) à la moyenne des DMC entre -65 et -45 jours avant l'incendie et supérieur (respectivement inférieur) à la moyenne de -45 à -8 jours (voir figure 3.5). Le modèle LGAM confirme la relation croissante entre DMC et le RBR , 25 jours avant l'incendie (voir figure 3.6). La faible importance (3 %) du DMC du jour de l'incendie dans le modèle GAM, la pondération très faible du modèle FLM entre -8 jours et le jour de l'incendie et le décalage temporel optimal du modèle LGAM de -25 jours, montrent que les valeurs à court terme du DMC n'influencent pas le RBR , contrairement à d'autres études sur la taille et l'activité des grands incendies (Barbero et al., 2019; Maffei and Menenti, 2019). Ces résultats sont cohérents avec la durée caractéristique du DMC (12 jours). Cet indice n'est pas en mesure d'influencer le RBR une semaine avant l'incendie. Ainsi, un forçage météorologique à moyen terme (2 mois) – pas de pluie et sécheresse atmosphérique marquée (Van Wagner et al., 1987) – est favorable aux hautes sévérités.

Les résultats confirment également l'impact central du $NDVI$ sur le RBR (voir figure 3.5). Les hautes (respectivement faibles) valeurs de RBR (plus hautes que la moyenne des RBR) sont atteintes pour des $NDVI$ décroissant (respectivement croissant) plus rapidement que la moyenne, et des valeurs de $NDVI$ plus élevées (respectivement faibles) que la moyenne entre -65 et -20 jours avant l'incendie et inférieures (respectivement supérieures) à la moyenne entre -20 jours et le jour de l'incendie. Un $NDVI$ qui diminue rapidement indique une diminution du combustible vivant/actif au cours du temps (Chuvieco et al., 2004, 1999; González-Alonso et al., 2006; Zhu and Liu, 2015). Le corollaire est une augmentation du combustible mort/sénescent (Brodrick and Asner, 2017; Pettorelli et al., 2005). L'utilisation des séries temporelles permet d'inférer l'évolution du ratio mort/vivant au cours du temps. L'augmentation de ce ratio (diminution du $NDVI$) indique que le combustible total sera facilement mobilisable par l'incendie (Andrews, 2018). Or le NBR_{post} est sensible aux conditions de surface post-incendie (cendres, etc.) (Hudak et al., 2007b; Kokaly et al., 2007; Lewis et al., 2021), résultant de la combustion du combustible mort et vivant. Ainsi un important ratio mort/vivant permettra d'atteindre de hautes valeurs de RBR pour un même NBR_{pre} . Ces résultats montrent l'importance des dynamiques temporelles du $NDVI$ que les modèles LGAM et GAM ne prennent pas en compte, ce qui pourrait expliquer en partie l'écart des performances de prédiction entre ces approches.

Le modèle FLM montre que les hauts (respectivement faibles) RBR sont atteints lorsque le DC prend des valeurs plus élevées (respectivement faibles) que la moyenne (entre [300,700]) entre -65 et -35 jours avant l'incendie et plus faibles (respectivement élevées) que la moyenne entre -35 jours et 0 jours avant l'incendie (voir figure 3.3). Cette situation peut se rencontrer dans des endroits où les précipitations sont faibles et/ou la température de l'air élevée pendant plusieurs mois (Van Wagner et al., 1987). Ces résultats sont en accord avec les modèles GAM et LGAM (voir figure 3.6), pour qui le DC n'est pas une

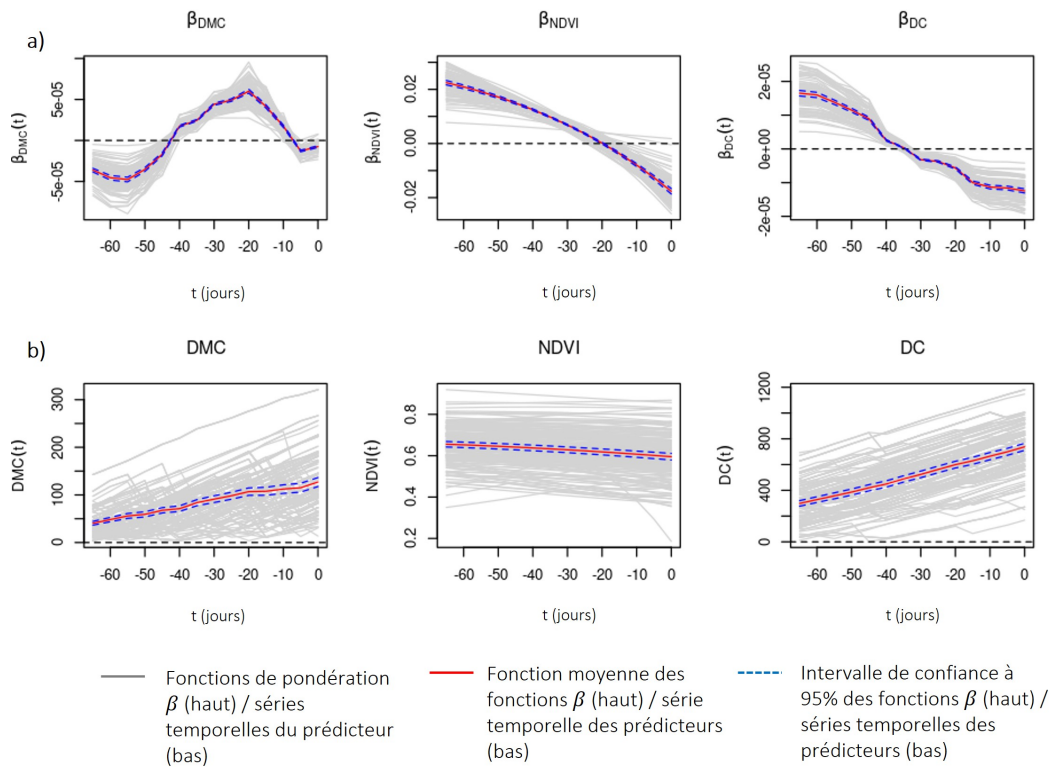


FIGURE 3.5 – Fonctions de pondération β des modèles FLM pour le *RBR* et les prédicteurs *NDVI*, *DMC* et *DC* (a). Ces fonctions pondèrent la différence, pour tout $t \in [-65, 0]$, entre la valeur à t d'une série temporelle de *NDVI* / *DMC* / *DC* et la moyenne des séries temporelles évaluée à t . Si $\beta(t) > 0$ alors la différence est pondérée positivement et $\beta(t) < 0$ alors la différence est pondérée négativement. Les hautes (respectivement basses) valeurs de *RBR* sont donc atteintes pour une différence de même signe (respectivement de signe opposé) que $\beta(t)$. Séries temporelles et séries temporelles moyennes de *NDVI*, *DMC*, *DC* pré-feu (b) d'une longueur de 65 jours avant l'incendie. $t = 0$ correspond au jour de l'incendie.

variable importante à -25 jours et 0 jour avant l'incendie. Ces résultats peuvent sembler contradictoires avec d'autres études qui indiquent l'influence positive du *DC* du jour de l'incendie sur la surface brûlée et la sévérité (Fang et al., 2015; Ruffault et al., 2018a). Cependant, quel que soit l'incendie du jeu de donnée, les valeurs de *DC* atteintes entre -35 jours et le jour de l'incendie (entre 400 et 740) sont au-delà des valeurs admises comme critiques, tant pour le *LFMC* que pour l'aléa incendie (Kang et al., 2023; Pellizzaro et al., 2007). Au final, les résultats du modèle FLM démontrent qu'il est suffisant qu'une sécheresse édaphique soit déjà bien établie 2 mois avant l'incendie pour que la sévérité soit élevée, ce qui est cohérent avec la durée caractéristique du *DC* (52 jours).

3.3.3 Impacts des prédicteurs statiques

Compte tenu de la faible importance des prédicteurs statiques dans le modèle FLM, seule la latitude est décrite. Bien que la latitude ait une faible importance dans le modèle FLM, elle est le prédicteur le plus important dans les modèles LGAM et GAM, leur permettant de maintenir de bonnes performances de prédiction. La latitude traduit des effets spatiaux, qui semblent être pris en compte dans les séries temporelles des prédicteurs temporels. Cela confirme que l'ajout de la dimension temporelle dans les modèles de prédiction permet de rendre compte des différences entre les positions géographiques, sinon uniquement quantifiables par un effet spatial difficilement interprétable.

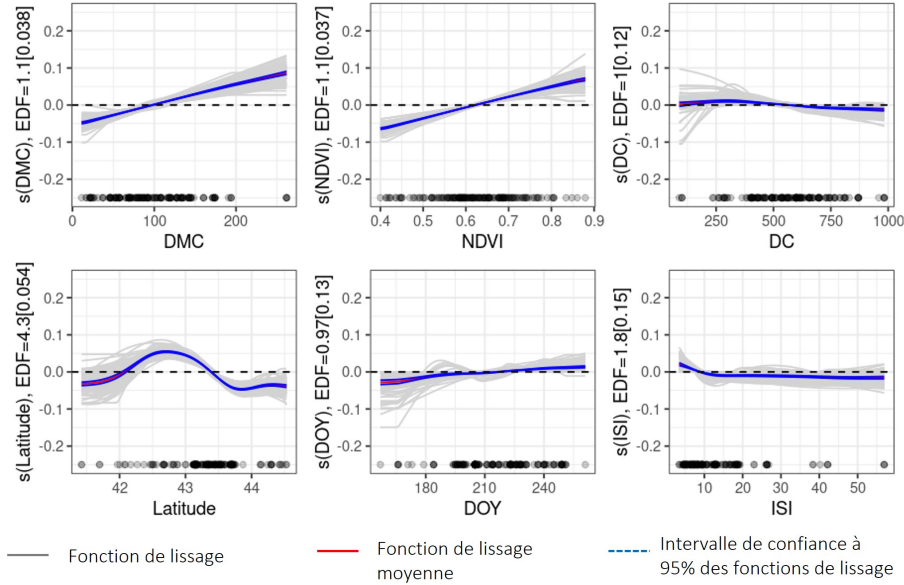


FIGURE 3.6 – Fonctions de lissage des prédicteurs sélectionnés par le modèle FLM pour le modèle LGAM du *RBR*. Les degrés de liberté sont un indicateur de la non linéarité des fonctions de lissage. Si le degré de liberté est égal à 1 alors la fonction est linéaire et s’il est strictement supérieur à 1 alors la fonction est non linéaire. Les intervalles de confiance à 95% des degrés de liberté sont entre crochets.

3.4 Résultats et discussion de la prédiction du NBR_{post} potentiel

Cette Section présente des résultats non publiés dans l’article, mais dont les bases théoriques sont les mêmes que pour le *RBR*.

3.4.1 Résultats de l’optimisation des modèles et performance de prédiction

Les variables sélectionnées par l’approche FLM sont, par ordre décroissant d’importance (entre parenthèse pour le FLM) : le *NDVI* (11%), le *DMC* (8%), l’*ISI* (8%), le cumul de précipitation entre les mois d’octobre et de décembre de l’année précédant l’incendie (*PrecTot*) (4%) et la latitude (2%). Les scores sélectionnés sont C_{NDVI1} et C_{NDVI2} pour le *NDVI* et C_{DMC1} et C_{DMC3} pour le *DMC*. Cette sélection et l’ordre d’importance des variables sont très similaires à ceux obtenus pour le *RBR* (voir Section 3.3.1). Contrairement aux modèles de prédiction du *RBR*, le *DC* et le *DOY* ne sont pas sélectionnés alors que c’est le cas pour la *PrecTot*. Pour le LGAM et le GAM, la latitude reste la variable la plus importante (11 % et 15%, pour le LGAM et le GAM respectivement). Elle supplante le *DMC* (9 % et 3%) et la *PrecTot* (9 % et 2.5%). Les autres variables ont une importance faible (inférieure à 2.5%)

La profondeur temporelle optimale pour le modèle FLM est $\delta_{opt} = -70$ [$\delta_{min} = -100, \delta_{max} = -25$] jours avant l’incendie et le décalage temporel optimal pour le modèle LGAM est $\tau_{opt} = -20$ [$\tau_{min} = 100, \tau_{max} = -25$] jours avant l’incendie. Ces résultats sont très cohérents avec ces obtenus pour le *RBR*, ie $\delta_{opt} = -65$ jours et $\tau_{opt} = -25$ jours. Par ailleurs les intervalles [$\delta_{min}, \delta_{max}$] et [τ_{min}, τ_{max}] pour les modèles FLM et LGAM de prédiction du NBR_{post} et du *RBR* s’intersectent. Cela confirme que les dynamiques de végétation et météorologiques durant les 65-70 jours avant l’incendie jouent un rôle déterminant pour prédire la sévérité estimée par ces deux *FSI*.

La performance de prédiction du modèle FLM supplante de nouveau les modèles LGAM et GAM. La figure 3.5 présente les boîtes à moustaches des *R* pour les modèles FLM, LGAM et GAM construits avec le

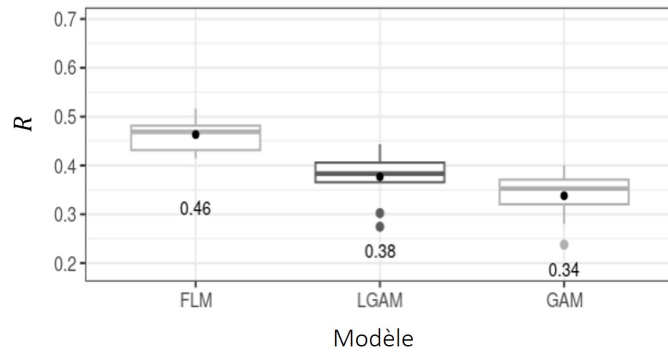


FIGURE 3.7 – Boîtes à moustaches des performances de prédiction (R) du NBR_{post} sur les 10 prédictions du jeu de test en fonction du modèle. La valeur numérique et le point noir correspondent à la moyenne des performances de prédiction.

jeu de variables sélectionnées par le modèle FLM. Le modèle FLM atteint en moyenne $R = 0.46$ contre $R = 0.39$ et $R = 0.32$ en moyenne pour les modèles LGAM et GAM respectivement. L'ordre de performance est le même que pour la prédiction du RBR , ce qui démontre que la dimension temporelle apporte une plus-value aux performances de prédiction. Aucune autre étude à ce jour ne s'est intéressée à la prédiction du NBR_{post} potentiel, ni à son explication. Cependant, la performance de prédiction du NBR_{post} est en deçà des attentes opérationnelles. Elle est bien moindre que celle du RBR ($R = 0.68$ pour le modèle FLM), et cette différence demanderait à être plus étudiée.

3.4.2 Impacts des prédicteurs temporels

La figure 3.8 présente les fonctions de pondération et les séries temporelles du $NDVI$ et du DMC pour les modèles FLM développés pour la prédiction du NBR_{post} . Les fonctions de pondération des séries temporelles du $NDVI$ (β_{NDVI}) suivent les mêmes variations que celles estimées pour le RBR (voir figure 3.5). Les faibles NBR_{post} (hautes sévérités) sont atteints pour des séries temporelles de $NDVI$ qui décroissent plus vite que la moyenne, qui prennent des valeurs supérieures à la moyenne entre 70 et 35 jours avant l'incendie et inférieures à la moyenne entre -35 jours et le jour de l'incendie. Inversement, les hauts NBR_{post} (faibles sévérités) sont atteints pour des $NDVI$ qui croissent plus vite que la moyenne. L'analyse effectuée pour le RBR reste donc valable. La différence de 15 jours entre les racines (pondération nulle) des fonctions de pondération du $NDVI$ pour le NBR_{post} et le RBR restent à explorer. Les fonctions de lissage du $NDVI$ des LGAM/GAM sont assez semblables et suggèrent une diminution de la sévérité (NBR_{post} élevés) avec l'augmentation du $NDVI$ (voir figure 3.9). Ce résultat est cohérent avec la fonction de pondération du modèle FLM qui est croissante. Les faibles $NDVI$ 20 jours avant l'incendie ou le jour de l'incendie sont des marqueurs indirect de la végétation sénescence/morte qui participe à la réflectance post-feu par sa combustion (faible NBR_{post}). Inversement les combustibles à $NDVI$ élevés (végétation vivante) seront moins affectés par l'incendie (NBR_{post} élevé).

La fonction de pondération du DMC dans le modèle FLM (voir figure 3.8) suit exactement les mêmes variations que pour le RBR , avec les mêmes valeurs temporelles indiquant les pondérations positives/négatives des différences à la moyenne des séries temporelles. Les hautes sévérités (NBR_{post} faibles) sont atteintes pour un forçage météorologique (sécheresse atmosphérique) qui augmente plus rapidement que la moyenne à moyen terme. La fonction de lissage pour le LGAM est décroissante et confirme que les hautes valeurs de DMC favorisent les hautes sévérités 20 jours avant l'incendie (voir figure 3.9), alors que le DMC du jour de l'incendie n'a que peu d'influence sur la sévérité (faible importance pour le GAM).

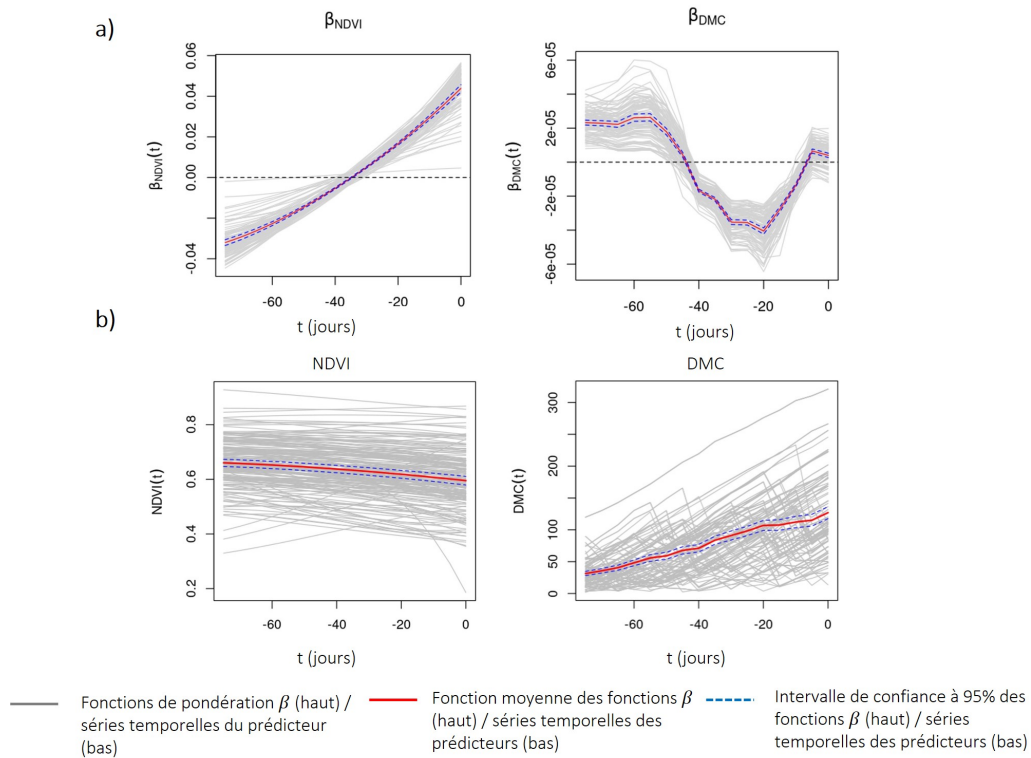


FIGURE 3.8 – Fonctions de pondération β des modèles FLM pour le NBR_{post} et les prédicteurs $NDVI$ (gauche) et DMC (droite) (a), et séries temporelles et séries temporelles moyennes de $NDVI$ et DMC pré-feu (b) d'une longueur de 70 jours avant l'incendie. $t = 0$ correspond au jour de l'incendie.

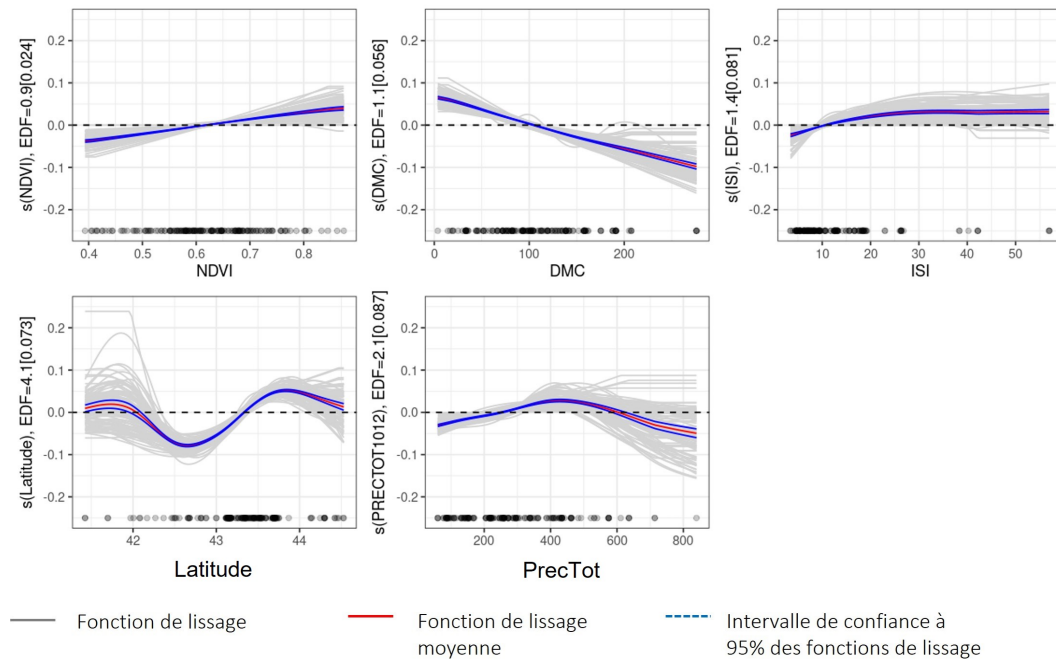


FIGURE 3.9 – Fonctions de lissage des prédicteurs sélectionnés par le modèle FLM pour le modèle LGAM du NBR_{post} .

3.4.3 Impacts des prédicteurs statiques

L'*ISI* a un coefficient positif (2.4×10^{-3}) pour l'approche FLM et une fonction de lissage croissante pour les approches LGAM/GAM (Voir figure 3.9). Ce résultat est cohérent avec les résultats obtenus pour le *RBR*, malgré que son influence reste contre-intuitive. La variable *PrecTot* a aussi un coefficient positif (1.5×10^{-3}) dans le modèle FLM, ce qui suggère que les pluies entre octobre et décembre de l'année précédant l'incendie diminuent la sévérité. Ce résultat est partiellement confirmé par la fonction de réponse des LGAM/GAM, pour la majorité des valeurs de pluie cumulée (inférieur à 600 mm). Les pluies d'automne favoriseraient la recharge des sols et l'activité printanière des végétaux impliquant une sévérité faible. Des études approfondies sont à mener pour tirer une conclusion certaine. Enfin, la latitude a un coefficient positif (1.5×10^{-3}) dans le modèle FLM. De même que pour le *RBR*, cette variable dont la fonction de lissage est très non linéaire, est très importante pour les LGAM/GAM. Elle permet à ces modèles de conserver une bonne qualité de prédiction. Cependant, c'est une variable qui intègre des effets spatiaux, pris en compte par les autres prédicteurs dans le modèle FLM.

3.5 Conclusion

L'introduction des séries temporelles d'indices issus de la télédétection optique et d'indices météorologiques constitue un apport significatif aux modèles de prédictions de la sévérité quel que soit le *FSI* (augmentation de 32% en moyenne de la performance de prédiction). Elle permet de mettre en évidence l'influence des variations de ces indices durant les 65-70 jours précédant l'incendie. Une augmentation plus rapide que la moyenne et de hautes valeurs le jour de l'incendie de la sécheresse atmosphérique (*Tair* élevée et *Rh* faible) en l'absence de précipitations ainsi qu'une diminution plus rapide que la moyenne et de faibles valeurs du *NDVI* le jour de l'incendie (augmentation du ratio combustible mort/vivant) permettent d'atteindre des sévérités plus élevées que la moyenne. La prise en compte des données météorologiques et de télédétection comme proxy de l'état du combustible est cruciale pour prédire la sévérité potentielle des incendies.

Cette étude s'est focalisée sur la prédiction de deux *FSI*, le *RBR* et le *NBR_{post}*, dont les performances de prédictions diffèrent. Le *NBR_{post}* (voir Équation (2.1)) n'intègre que des informations post-feu alors que le *RBR* intègre des informations pré-feu (voir Équation (2.4)). Aussi, l'influence des expressions mathématiques sur les performances de prédiction doit être mieux comprise.

3.6 Article associé : "Improved fire severity prediction using pre-fire remote sensing and meteorological time series : application to the French Mediterranean area"

Agricultural and Forest Meteorology

Improved fire severity prediction using pre-fire remote sensing and meteorological time series: Application to the French Mediterranean area

--Manuscript Draft--

Manuscript Number:	
Article Type:	Research Paper
Section/Category:	Fire Meteorology
Keywords:	Fire severity; Pre-fire conditions; Time series; optical remote sensing; Weather; Fuel
Corresponding Author:	Victor Penot Center for the Study of the Biosphere from Space FRANCE
First Author:	Victor Penot
Order of Authors:	Victor Penot Thomas Opitz François Pimont Olivier Merlin
Abstract:	<p>Fire severity, or how an environment is affected by fire, can be estimated over large areas using remotely sensed fire severity indices, such as the Relative Burnt Ratio (RBR). RBR predictions are generally based on data collected on a single date immediately before the fire, or on data aggregated over time to a scalar value. However, accurate temporal and spatial prediction of RBR remains challenging. To improve the predictability of RBR, we build new predictive models using time series spanning several months before fire of fuel proxies, derived from optical remote sensing and meteorological data. The approach is applied to the fires of the French Mediterranean area during the summers of the 2016-2021 period. The Lagged Generalized Additive Model (LGAM) and the Functional Linear Model (FLM) are used to estimate the influence of explanatory variables up to several months prior to the fire on RBR, while the Generalized Additive Model (GAM), which relies on immediate pre-fire predictors at a single date, is used as a benchmark. Training and prediction are carried out at the fire-land-cover spatial scale with training dataset composed of fires independent of those in the test datasets. FLM achieves the best prediction accuracy on test data ($R=0.68$, $RMSE=0.057$) compared to LGAM ($R=0.60$, $RMSE=0.063$) and the benchmark ($R=0.52$, $RMSE=0.069$) and is also less sensible to overfitting. The selected FLM correctly predicts even the highest RBR values when the Normalized Difference Vegetation Index decreases faster than on average and also when the fire-weather Duff Moisture Code increases faster than on average over the 65 days before fire. The 17% decrease in the RMSE of FLM predictions compared to the RMSE of GAM predictions shows that knowledge of fuel dynamics up to two months before a fire provides valuable information for ranking areas according to fire severity.</p>
Suggested Reviewers:	<p>Alan Taylor aht1@psu.edu He studied wildfire conditions, including fire severity prediction, particularly in the western USA. He used a variety of methodological approaches.</p> <p>Sean A. Parks sean.parks@usda.gov He studied wildfire conditions, including fire severity prediction, and developed a fire severity index used in our study. He developed a predictive modelling approach for fire severity in western US forests.</p> <p>Olga Viedma Olga.Viedma@uclm.es She has studied forest fire disturbance in the Mediterranean region. She is therefore well acquainted with the meteorological and environmental conditions in Mediterranean forests.</p>

1 Highlights

2 **Improved fire severity prediction using pre-fire remote sensing and meteorological time se-**
3 **ries: Application to the French Mediterranean area**

4 Victor Penot, Thomas Opitz, François Pimont, Olivier Merlin

- 5 • Fire severity index is predictable at the scale of fire–land-cover with 11% error
- 6 • Knowledge of pre-fire fuel dynamics improves fire severity index prediction
- 7 • Leveraging memory of fuel dynamics for 65 days before fire reduces the error by 17%

Improved fire severity prediction using pre-fire remote sensing and meteorological time series: Application to the French Mediterranean area

Victor Penot^a, Thomas Opitz^b, François Pimont^c, Olivier Merlin^a

^a*CESBIO, CNES/CNRS/IRD/UPS, Toulouse, France*

^b*BioSP, INRAE, Avignon, France*

^c*URFM, INRAE, Avignon, France*

Abstract

Fire severity, or how an environment is affected by fire, can be estimated over large areas using remotely sensed fire severity indices, such as the Relative Burnt Ratio (RBR). RBR predictions are generally based on data collected on a single date immediately before the fire, or on data aggregated over time to a scalar value. However, accurate temporal and spatial prediction of RBR remains challenging. To improve the predictability of RBR, we build new predictive models using time series spanning several months before fire of fuel proxies, derived from optical remote sensing and meteorological data. The approach was applied to the fires of the French Mediterranean area during the summers of the 2016-2021 period. The Lagged Generalized Additive Model (LGAM) and the Functional Linear Model (FLM) were used to estimate the influence of explanatory variables up to several months prior to the fire on RBR, while the Generalized Additive Model (GAM), which relies on immediate pre-fire predictors at a single date, is used as a benchmark. Training and prediction were carried out at the fire-land-cover spatial scale with a training dataset composed of fires independent of those in the test datasets. FLM achieved the best prediction accuracy on test data ($R=0.68$, $RMSE=0.057$) compared to LGAM ($R=0.60$, $RMSE=0.063$) and the benchmark ($R=0.52$, $RMSE=0.069$) and was also less sensible to overfitting. The selected FLM is able to correctly predict even the highest RBR values when the Normalized Difference Vegetation Index decreases faster than on average and also when the fire-weather Duff Moisture Code increases faster than on average over the 65 days before fire. The 17% decrease in the RMSE of FLM predictions compared to the RMSE of GAM predictions shows that knowledge of fuel dynamics up to

two months before a fire provides valuable information for ranking areas according to fire severity.

Keywords: Fire severity, Pre-fire conditions, Time series, Optical remote sensing, Weather, Fuel

1. Introduction

The French Mediterranean is a very fire-prone area and experiences many fires every year (Galizia et al., 2021), with the number of fires expected to increase in the context of climate change (Barbero et al., 2020; Fargeon et al., 2020; Pimont et al., 2022). The wildland fire risk is the combination of the occurrence of a wildfire and its expected outcomes, which are defined by its effects on the objects it affects (Bachmann and Allgöwer, 2001). The occurrence and one of the expected outcomes, fire size, for which relatively long observational records are available (Fox et al., 2018; Hernandez et al., 2015a; Pimont et al., 2021), or fire behaviour (Salis et al., 2016, 2023), have been extensively studied and used in prediction models. Another complementary outcome is the severity of a fire once ignited, as it assesses the impact of wildfires on the environment (Key and Benson, 2005). More specifically, it aims to quantify the consumption of above- and below-ground organic matter by fire (Keeley, 2009). Fire severity has been quantified locally with ground measurements of fire effects such as organic matter loss, crown volume scorch, tree mortality or post-fire twig diameter (Jain and Graham, 2007; Keeley, 2009; Miller et al., 2023), all linked to fire intensity (Keeley, 2009; Williams et al., 1998) and burning efficiency (Bountouraby et al., 2023).

Remote sensing has enabled to estimate fire severity over large areas at reasonable costs, thanks to fire-severity indices (FSI) derived from high resolution (10 -100 m) optical imagery (Key and Benson, 2005; Miller and Thode, 2007; Parks et al., 2014a). The most popular FSI are the Normalized Burnt Ratio (NBR) – an index that combines Near Infrared (NIR) and Shortwave InfraRed (SWIR) bands, and its derivatives, the Difference Normalized Burnt Ratio (DNBR) (Key and Benson, 2005) – a measure of absolute change – or the Relative Burnt Ratio (RBR) (Parks et al., 2014a) – a pre-fire vegetation normalized version of the DNBR. They show significant positive statistical correlations with ground measurements of fire severity (Escuin et al., 2008; Keeley, 2009; Key and Benson, 2005; Miller and Thode, 2007; Parks et al., 2014a; Soverel et al., 2010) and also with radiative transfer modelling of burnt scenes (Chuvieco et al., 2006) over a variety of

60 landscapes (Parks et al., 2019). More specifically, RBR has shown good agreement with Mediter-
61 ranean ground measurements (Fernández-Guisuraga et al., 2023; Viedma et al., 2020) and exhibits
62 relatively better performance at detecting high severity effects across the full range of pre-fire veg-
63 etation cover (Parks et al., 2014a), while DNBR is particularly sensitive to high pre-fire biomass
64 (Miller and Thode, 2007).

65 Assessing the severity of fires using remote-sensing-based FSI has made it possible to charac-
66 terize the large range of conditions encountered before and during fires. To understand the factors
67 driving fire severity, many studies have explained the variability of FSI using machine learning
68 or statistical modelling (Fang et al., 2018; Lecina-Diaz et al., 2014; Viedma et al., 2020). Three
69 groups of factors have been clearly identified: fuel (structure, dominant species and and physio-
70 logical activity), weather (day of fire and pre-fire), and topography. They are described in the three
71 following paragraphs.

72 The status of live fuels in relation to fire severity can be well monitored using indices de-
73 rived from satellite optical remote sensing (Costa-Saura et al., 2022; Fernández-García et al.,
74 2022), particularly the Normalized Difference Vegetation Index (NDVI) (Parks et al., 2018a; Tay-
75 lor et al., 2021). NDVI is computed from the Red and Near InfraRed (NIR) channels as fol-
76 lows $NDVI = \frac{NIR-Red}{NIR+Red}$ (1). It is directly sensitive to vegetation chlorophyll content and also
77 used to quantify the living biomass (González-Alonso et al., 2006; Zhu and Liu, 2015). In ad-
78 dition, NDVI is an indirect proxy of live fuel moisture content (Chuvieco et al., 1999; García
79 et al., 2020; Yebra et al., 2013), specifically for low shrubland (Chuvieco et al., 2004; Yebra
80 et al., 2008). The high revisit frequency of Landsat-7/8/9 or Sentinel-2A/B constellations enables
81 weekly monitoring of fuel phenological stages. The spatial distribution of dominant species and
82 fuel structure, which is commonly provided by vegetation maps, also helps to explain fire sever-
83 ity. In particular, open/closed forest and large forest classes (deciduous/evergreen and needle-
84 leaf/broadleaf/shrubland) have shown good FSI explanatory abilities (Costa-Saura et al., 2022;
85 Taylor et al., 2021; Viedma et al., 2020, 2014).

86 Weather, and more specifically synoptic patterns of weather conditions, have shown to be
87 strong drivers of fire occurrence (Barbero et al., 2019; Pimont et al., 2021), fire size (Hernan-
88 dez et al., 2015a,b; Ruffault and Mouillot, 2015), fire intensity (Byram, 1959; Hernandez et al.,

89 2015a,b; Rothermel, 1972), and fire severity (Birch et al., 2015; Fang et al., 2015). On the
90 one hand, hourly conditions drive the moisture content of dead fine fuel (Bradshaw et al., 1984;
91 de Groot, 1987; Van Wagner et al., 1987) and the fire behaviour (Byram, 1959; Rothermel, 1972).
92 On the other hand, mid-term to long-term conditions drive the hydric state (Bradshaw et al., 1984;
93 Littell et al., 2016; Parks et al., 2014b; Taylor et al., 2021) and biomass production of living fuel
94 (Parks et al., 2014b; Piedallu et al., 2019). These factors have been integrated in many specific
95 weather indices. For instance, the Fire-Weather Index prediction system of the Canadian Forest
96 Fire Danger Rating System (CFFDRS) (Van Wagner et al., 1987) provides convenient scalar in-
97 dices to rate fire danger by means of codes, namely the Drought Code (DC), the Duff Moisture
98 Code (DMC) and the Initial Spread Index (ISI), calculated using noon meteorological data only
99 (wind speed, daily cumulated precipitations, air temperature, relative humidity (RH)). Originally
100 built to rate forest fire weather in the Canadian forests (Van Wagner et al., 1987), these codes have
101 been shown to be particularly relevant in the Mediterranean area (Barbero et al., 2020; Dupuy et al.,
102 2020; Fargeon et al., 2020; Ganteaume and Barbero, 2019), and are operationally used during the
103 fire season in Canada, France and by the European Forest Fire Information System (EFFIS).

104 Topography also plays an important role for fire severity. On the one hand it is a driver of
105 active fire, particularly the slope that interacts with wind speed/direction and fuel (Byram, 1959;
106 Rothermel, 1972; Viedma et al., 2020). However, due to the mismatch in spatial scale between
107 the decametric resolution of available slope products and the kilometric resolution of synoptic
108 wind and RH data, this effect is difficult to take into account using common large-scale weather
109 products. On the other hand, topography interacts with living fuel. In fact, topography influences
110 vegetation type, water availability and biomass production at all scales (Dillon et al., 2011; Holden
111 et al., 2009; Parks et al., 2018a).

112 Given the recent focus of forest managers on assessing fire severity, many studies have not only
113 focused on improved understanding of FSI variability but also on its prediction, especially short-
114 term forecasting (Fernández-García et al., 2022; Holden et al., 2009; Parks et al., 2018a; Taylor
115 et al., 2021). Although intra-fire variability may be well explained (Pascolini-Campbell et al.,
116 2022; Wells et al., 2019), predicting the FSI variability across different fires remains challenging
117 (Fernández-García et al., 2022; Parks et al., 2018a; Taylor et al., 2021; Wells et al., 2019). In

118 practice, this predictability is usually assessed by a training/testing approach (Taylor et al., 2021):
119 the whole dataset of fires is split in a training dataset (used to train the model), and a test dataset
120 (different fires from training datasets). This allows to check the predictability of FSI in another
121 place and time (test dataset) than those of the training dataset (where the procedure can be repeated,
122 or cross-validation can be used, to obtain several configurations of train-test data), which is the
123 essential aim of fire danger forecasting.

124 To date, all the studies describing and predicting the observed variability of FSI have used
125 explanatory and predictive factors that either reflect the conditions immediately prior to the fire
126 (e.g. immediate pre-fire NDVI (Costa-Saura et al., 2022; Taylor et al., 2021)) or represent scalar
127 summaries of past conditions (e.g. remote sensing indices z-score (Costa-Saura et al., 2022),
128 DC). However, using knowledge on the dynamics of such factors during a time interval prior to
129 fire could allow for improved prediction performance. In fact, they would allow to capture more
130 completely than immediate pre-fire measurements, how weather dynamics act on the dynamics of
131 the volume and state of biomass (growth, drying, dying). Moreover, such functional information is
132 based on series of measurements and could therefore also be less noisy than the measurement at a
133 single time point. Especially, to the knowledge of the authors, current studies have not considered
134 yet the temporal information provided by pre-fire time series *per se*, such as time-lagged scalar or
135 temporal evolution of pre-fire conditions (e.g. spring to summer mortality/drying). Nevertheless,
136 optical remote sensing and meteorological data are available at least on a weekly basis, making it
137 possible to use pre-fire NDVI and meteorological index time series to predict FSI.

138 Statistical regression models such as the Generalized Additive Model (GAM) have proven
139 their usefulness in ecology (Frescino et al., 2001; Guisan et al., 2002; Ohana-Levi et al., 2020) or
140 fire science (Estes et al., 2017; Fassnacht et al., 2021) because they are able to model a non-linear
141 response, are easily interpretable and allow for precise likelihood-based uncertainty assessment.
142 They can be fed with immediate pre-fire inputs or with time-lagged inputs, but they do not allow
143 to take into account the whole dynamics of the fuel proxies and of the meteorological conditions
144 prior to the fire. To this end, functional data analysis (Ramsay, 2005) provides the appropri-
145 ate framework to work with functional predictors, such as time series of pre-fire measurements.
146 Scalar-on-function regressions, such as the Functional Linear Model (FLM), take functions as

147 inputs to predict scalar values, where different approaches are available to represent potentially
148 relevant functional features of time series (Kokoszka and Reimherr, 2017; Ramsay, 2005). For
149 instance, such models have been used to predict coastal hypoxia from remote sensing time series
150 (Li et al., 2023), total suspended solid (oceanography) as a function of short/mid wavelength spec-
151 trum (Acar-Denizli et al., 2018) or habitat mapping (vegetation species) with NDVI time series
152 (Pesaresi et al., 2022).

153 In this context, this study focuses on two research questions: (1) is the inter-fire variability
154 of RBR explainable and predictable using readily available ancillary (remote sensing and mete-
155 orological) data, and with what accuracy? (2) Does knowledge of the full pre-fire dynamics or
156 time-lagged values of NDVI, DC and DMC improve RBR predictions compared to state-of-the-
157 art approaches based on an immediate pre-fire single date? To address both issues, this study
158 investigates how the severity (RBR) of 79 summer fires that occurred during 2016-2021 in the
159 French Mediterranean area can be explained by different types of prediction models. The paper is
160 structured as follows. Section 2 describes this study area, the remote sensing and meteorological
161 data used, and the models trained and tested. Section 3 presents the results obtained by the dif-
162 ferent models while Section 4 discusses them. Finally, Section 5 underlines the main advances of
163 this study and suggests future ways of improvement.

164 **2. Material and methods**

165 *2.1. Study area and fire-land cover dataset*

166 This study investigates 79 forest fires that had occurred in the French Mediterranean area be-
167 tween 2016 and 2021, during the summer fire season (June-September). The Mediterranean region
168 of France has a wide range of forest cover and various topographic profiles (Fargeon, 2019), from
169 the urbanised and agricultural coastal plains to the wooded hills and mountains of Corsica and the
170 hinterland. The biogeographical region shows the same main characteristics (e.g. precipitation,
171 sunshine, air temperature), with warm and dry summers and mild winters, except for the moun-
172 tainous area that combines both Mediterranean and mountainous influence (Barbero et al., 2019).
173 Figure 1 maps the study area in the western Mediterranean area and the studied fire locations. The




Figure 1: Map of the French Mediterranean area and studied fires.

174 minimum, maximum and mean fire elevation is 5 m, 1,439 m and 285 m, respectively. Fires took
 175 place mainly during July (26 fires) and August (35 fires), while the rest were split between the
 176 beginning of the season, June (6 fires), and the end of the season, September (12 fires). During the
 177 study period, the years 2016 (21 fires) and 2017 (27 fires) witnessed heatwave/drought conditions
 178 (Fargeon et al., 2020; Ruffault et al., 2023).

179 The fire perimeters were provided by the National French Forest Service (Office National des
 180 Forêts, ONF). To put focus on areas that have burnt naturally, all pixels within a buffer of 50
 181 m within the fire perimeter and along the fire area boundary were removed to take into account
 182 firefighting actions. For the same reason, pixels within 100 m of roads and built areas are removed
 183 to take into account pre-fire mitigation policies (fuel clearance).

184 Our study focuses on the scale of land-cover (LC) types. Consequently, we define the ob-
 185 servations of the response variable as the spatial intersection between the perimeter of a fire and
 186 land-cover patches of given types (Fire–LC pairs) to obtain phenologically consistent and fire-
 187 severity-related aggregates (Estes et al., 2017; Fang et al., 2018, 2015) within relatively homoge-
 188 neous spatial units. The LC perimeters and classification were provided by the National French
 189 Forest Database BDForet V2 from Institut Géographique National (IGN). First, ten classes of LC
 190 are constructed, according to LC structure (open, closed, shrublands) and dominant tree classes
 191 (coniferous, deciduous, mixed, shrublands). Only fire–LC intersections greater than 13.5 ha are
 192 considered, resulting in a selection of 79 wildfires out of the 215 fires mapped and the creation

Table 1: LC classes, number of fire–LC per LC class and canopy structure types. Forested area with no forest LC class is an area after disturbance (clear cut, fire). They were mapped before 2016

Land cover	Number of fire–LC pair	Canopy structure type
Mixed closed canopy forest	10	Closed
Broadleaf closed canopy forest	24	
Coniferous closed canopy forest	40	
Mixed open canopy forest	12	Open
Coniferous open canopy forest	18	
Broadleaf open canopy forest	20	
Herbaceous	2	Shrubland
Shrublands	44	
Closed canopy forest with no forest	7	
Open canopy forest with no forest	2	

193 of 179 fire-land cover (fire–LC) pairs with a final filtered pixel area ranging from 14 ha to 1238
 194 ha (Table 1). These spatial intersections will be used to average ancillary data and RBR. We also
 195 group land cover according to its canopy-structure type for further analysis. By definition, the
 196 three types correspond to the percentage of trees capable of reaching a height of over 5 meters at
 197 maturity *in situ* : between 10 and 40% (open forest), greater than or equal to 40% (closed forest)
 198 and less than 10% (non-forest, including shrublands and herbaceous).

199 2.2. Remotely sensed reflectance data

200 Sentinel-2 and Landsat-7/8 data are used in this paper to derive spectral FSI and pre-fire time
 201 series of NDVI. The joint use of Landsat-7/8 and Sentinel-2 data increases the temporal resolu-
 202 tion. Landsat-7 Enhanced Thematic Mapper (ETM+) and Landsat-8 Operational Land Imager
 203 (OLI) provide reflectance data with a 16-day revisit period, with an 8-day shift between Landsat-7
 204 and Landsat-8. Landsat data were downloaded from USGS Earth Explorer platform/Landsat Col-
 205 lection 2 Level-2 Science Products from 2015 to 2021. At this product level, shortwave optical
 206 data are provided directly to the bottom of the atmosphere reflectances at their native resolution of
 207 30 m. Landsat-7 data were processed with the Landsat Ecosystem Disturbance Adaptive Process-
 208 ing System (LEDAPS) algorithm (Version 3.4.0) (Schmidt et al., 2013) and Landsat-8 data with

209 the Land Surface Reflectance Code (LaSRC) algorithm (Version 1.5.0) (Vermote et al., 2016).
 210 Sentinel-2A/2B satellites both provide reflectances with a 10-day revisit period, with a 5-day shift
 211 between Sentinel-2A and Sentinel-2B satellites. Data between 2016 and 2021 were downloaded
 212 from Theia-land with a level 2A-FRE processing, corrected for atmospheric and topographic ef-
 213 fects thanks to the MAJA software (Baetens et al., 2019; Hagolle et al., 2008, 2010, 2015). To
 214 filter Sentinel-2 pixels spatially (see 2.1), Sentinel-2 pixels are aggregated from 10 m and 20 m
 215 to 30 m resolution (weighted average for band values according to the fraction of the source pixel
 216 that is covered by the destination pixel, and mode, i.e. value which appears most often of all the
 217 sampled points, for mask values) on the Landsat-7/8 grid.

218 2.3. Spectral FSI

219 For each fire, FSI are computed from immediately pre-fire and post-fire overpasses of the
 220 Sentinel-2 Multispectral Imager images with a minimum frequency of clear pixels of 80% as we
 221 prioritise the closest overpass to the start (mean[standard deviation] =6.5[5.5] days before the fire)
 222 and end (mean[standard deviation] =7.6[7.5] days after the fire) of each study fire. The same
 223 pixel locations are used in pre- and post-fire images. We used NIR (B8A band) and Short-Wave
 224 InfraRed 2 (SWIR2 – B12 band) to calculate the following FSI:

225 Normalized Burnt Ratio (López García and Caselles, 1991)

$$NBR = \frac{(NIR - SWIR2)}{(NIR + SWIR2)} \quad (2)$$

226 Relativized Burnt Ratio (Parks et al., 2014a)

$$RBR = \frac{NBR_{prefire} - NBR_{postfire}}{NBR_{prefire} + 1.001} \quad (3)$$

227 2.4. Sets of explanatory predictors of RBR variability

228 In the following sections, we describe the different variables, either functional or scalar. Table 2
 229 summarizes all the variables initially used in all the models.

230 2.4.1. Length of time series

231 In order to include all the most relevant variations of explanatory variables before fires, we
 232 choose a maximum time series length of 185 days before fire for the following reasons. NDVI

233 times series, and particularly their variations (increase/decrease), show the seasonal trends in active
234 biomass (Reed et al., 1994; Zhang et al., 2003). In the Mediterranean regions, NDVI shows a
235 spring increase until early summer and a decrease during summer drought until September (Chéret
236 and Denux, 2007, 2011). Since the major part of fire activity occurs around the end of July, a 185-
237 day window encompasses both spring living fuel activity and summer decrease of activity. In
238 addition, DC and DMC reflect seasonal to monthly weather conditions (Van Wagner et al., 1987)
239 whose trend and variations are considered from late winter to the summer fire season (Ruffault
240 et al., 2018a).

241 2.4.2. *Vegetation data*

242 NDVI time series were computed from NIR and Red bands provided by both Sentinel-2 data
243 and Landsat-7/8 data. Only overpass dates that supply at least 75% of clear pixels among the
244 pixels selected to compute FSI (see 2.3) in each fire–LC pair and date were kept, and band values
245 were averaged for each fire–LC and date.

246 To be used as variable in an FLM, time series must be provided with the same time step and the
247 same length (same total number of time steps). However, fires took place at different times (year
248 and day of year) and places (different Landsat/Sentinel tiles), and were variably affected by cloud
249 cover. Consequently, Red and NIR bands, once averaged at fire–LC scale, were resampled during
250 a period of 185 days before fire. To do so, we first apply a band value selection for each Fire–LC.
251 We start by deleting band values greater than the average band value (z-score greater than 3 (Yaro
252 et al., 2023)), possibly contaminated by undetected clouds in the mask layer (Irish, 2000; Tarrío
253 et al., 2020; Zhu et al., 2018). Then, we use smoothed B-spline interpolation as suggested in
254 (Ramsay, 2005) and done in (Pesaresi et al., 2022), with restricted maximum likelihood (REML)
255 for automatic smoothing parameter optimization using the R package mgcv (Wood, 2011). We
256 select the band values whose difference from the interpolated data is not labelled as outlying
257 according to the interquartile range criterion with a parameter of 1.5 (Hoaglin, 2003; Hoaglin and
258 Iglewicz, 1987; Hoaglin et al., 1986). Finally, if the number of selected band values is greater than
259 6, we interpolate these values as before with B-splines, using a 5-day timestep. NDVI time series
260 are computed from the smooth resampled time series of Red and NIR using the R package fda.usc

261 (Febrero-Bande and De La Fuente, 2012) following equation (1).

262 2.4.3. *Meteorological data and fire weather indices*

263 In France, the SAFRAN (Système d'Analyse Fournissant des Renseignements Atmosphériques
264 a la Neige ; Analysis system providing data for the snow model) reanalysis dataset (Vidal et al.,
265 2010) provides daily-averaged meteorological data over an 8 km grid that can be used to calculate
266 CFFDRS codes : air temperature (average and maximum), RH, wind speed and 24-hour cumula-
267 tive rain.

268 We compute the codes from the CFFDRS System, from noon meteorological variables es-
269 timated with mean daily data from the SAFRAN dataset whereas air temperature is set to the
270 maximum air temperature as in (Barbero et al., 2019), during the 185 days preceding the fire. DC
271 estimates the long-term availability of water (slow-drying fuel) in soils at a depth of 10 to 20 cm
272 and integrates a simplified expression of potential evapotranspiration. It has a classical change
273 time of 52 days, i.e the free moisture content of the theoretical fuel represented by DC decreases
274 by 2/3 in 52 days under constant weather conditions (de Groot, 1987). DC depends only on the
275 24h-cumulative rain and the air temperature. It has been shown that DC may be linked to fuel
276 water content (grass and shrub species) in the Mediterranean area (Pellizzaro et al., 2007; Ruffault
277 et al., 2018b; Viegas et al., 2001). DMC rates water availability in mid-to surface soil (5-10 cm)
278 and it has a change time of 12 days (de Groot, 1987). It depends on the RH, the 24h-cumulative
279 rain and the air temperature. Finally, ISI is a composite index that links wind speed to a hypothetic
280 dry fuel surface layer and is linked to fire ignition, initial propagation (Van Wagner et al., 1987)
281 and fire spread (Wang et al., 2023). It is only computed for the day of the fire, depends on the RH,
282 the 24h-cumulative rain, the air temperature and the wind speed. These codes are calculated using
283 the cffdrs R package (Wang et al., 2017).

284 In the Mediterranean region, rainfall mainly occurs during fall and winter, loading the soil with
285 reserves (Allard et al., 2008; Limousin et al., 2012), while drought conditions are often observed in
286 summer in combination with high air temperatures (Ruffault et al., 2018a). Since wet/moist condi-
287 tions during the fall may have an influence on the fire activity during the following year (González
288 et al., 2018; Holz et al., 2012), we compute the cumulative rain during the fall season preceding

289 the fire (October-December of pre-fire year). In addition, since drought and heat wave conditions
290 may have a persistent effect over live fuel during the following month/year (Senf and Seidl, 2021),
291 we also compute the mean summer daily maximum air temperature (June - September of pre-fire
292 year) of the year preceding the fire.

293 2.4.4. *Topographic data*

294 French National Elevation Database (BDAlti) from IGN provides 25 m-spatial resolution digi-
295 tal elevation model. We decided to keep elevation and slope data, and we computed their arithmetic
296 average within the spatial extent of each fire-LC pair.

297 2.4.5. *Location data and day of year*

298 To consider the possible temporal shifts between times series, the day of year (DOY) is also
299 used as an scalar input variable. In the spatial dimension, location along the Mediterranean arc has
300 been shown to be a predictor variable for large fire activity (Castel-Clavera et al., 2023; Ganteaume
301 and Barbero, 2019), occurrence (Castel-Clavera et al., 2023), and of fire severity in the USA (Parks
302 et al., 2019). Longitude and Latitude of each Fire-LC are selected as input scalar variables.

303 2.5. *Models*

304 Three model classes were implemented to evaluate the impact on RBR prediction of pre-fire
305 times series up to 185 days before the fire events: FLM (2.5.1), GAM with scalar time-lagged
306 predictors and GAM with only measured pre-fire inputs (2.5.2)

307 2.5.1. *FLM description*

308 The FLM extends the multiple linear regression to functional predictors. Scalar-on-function
309 regression explains a scalar output – here chosen as RBR – using functional predictors (Ramsay,
310 2005). As functional variables, we use DC and DMC time series as well as resampled NDVI
311 time series (see Section 2.4.2) with a sample frequency of 5 days. Pre-fire DC and DMC are di-
312 rectly used without pre-processing due to their relative smoothness. Given the functional variables
313 $k \in \{NDVI, DMC, DC\}$, the corresponding coefficient functions β_k are estimated in the following
314 regression equation:

Table 2: Time series and scalar variables used as predictors of RBR

Predictor variable	Times series / Scalar	Units	Data Source
NDVI	Times series	-	Sentinel-2 / Landsat-7/8
DC	Time series	-	SAFRAN
DMC	Time series	-	SAFRAN
ISI	Scalar	-	SAFRAN
Cumulative fall rainfall – pre- year fire	Scalar	mm	SAFRAN
Mean maximum summer air tem- perature – pre- year fire	Scalar	° C	SAFRAN
DOY	Scalar	-	-
Elevation	Scalar	m	BD Alti
Slope	Scalar	°	BD Alti
Longitude	Scalar	°	-
Latitude	Scalar	°	-

$$\begin{aligned}
RBR_i = & \alpha + \int_{\delta}^0 \beta_{NDVI}(t)NDVI_i(t)dt \\
& + \int_{\delta}^0 \beta_{DC}(t)DC_i(t)dt \\
& + \int_{\delta}^0 \beta_{DMC}(t)DMC_i(t)dt + LM_i + \epsilon_i
\end{aligned} \tag{4}$$

315 with $\alpha \in \mathbf{R}$, the intercept; $i = 1, \dots, N$, N size of the sample; $\epsilon_i \sim \mathcal{N}(0, \sigma^2)$, independent for
316 different i ; $\delta \in [-185 ; -15]$ time depth (number of days before fire); LM_i a linear combination
317 of scalar predictors (see Table 2).

318 For each functional predictor $k \in \{NDVI, DMC, DC\}$, β_k – the weighting function – is a
319 constructed as a smooth function and is interpretable (Goldsmith and Scheipl, 2014). If k is cen-
320 tered, then when $|\beta_k(t)|$ is relatively large it is very influential on the output, and the increas-
321 ing/decreasing influence on the output is given by its sign (Ramsay et al., 2009).

322 Among the various possibilities of defining an FLM, the functional principal-component re-
323 gression (FPCR) (Cardot et al., 1999) is based on the functional principal component (PC) de-
324 composition of each functional predictor, providing an orthonormal functional basis with a fixed
325 number of basis functions than are chosen to explain as much variance of predictors as possible
326 over the definition domain $[\delta, 0]$. Then, each centred predictor $k \in \{NDVI, DMC, DC\}$ can be
327 linearly decomposed on this basis $(PC_{kj})_{j \in \mathbf{N}^*}$, $(C_{kj})_{j \in \mathbf{N}^*}$ being the coordinates of each centred pre-
328 dictor in this basis, hereafter named PC-scores. Each variable is decomposed on its first 3 PC, that
329 represent 99%, 88%, 96% of the total variance for NDVI, DMC and DC, respectively, for the all
330 fire–LC datasets when $\delta = -185$ days.

331 With FPCR, each coefficient function β_k , $k \in \{NDVI, DMC, DC\}$, can be written as the follow-
332 ing linear combination of its first 3 PC variables $(PC_{kj})_{1 \leq j \leq 3}$, $\beta_k = a_{k1}PC_{k1} + a_{k2}PC_{k2} + a_{k3}PC_{k3}$
333 where the coefficients a_{ki} must be estimated, such that FPCR is equivalent to a standard multilinear
334 regression model (Goldsmith and Scheipl, 2014; Ramsay et al., 2009) following the equation, with
335 $\alpha' \in \mathbf{R}$:

$$\begin{aligned}
RBR_i = & \alpha' + \sum_{k \in \{NDVI, DMC, DC\}} [a_{k1}C_{k1i} + a_{k2}C_{k2i} + a_{k3}C_{k3i}] \\
& + LM_i + \epsilon_i
\end{aligned} \tag{5}$$

336 In this study, FLM is used to estimate the 9 parameters for the three functional predictors
337 (3 PC-scores per functional variables) and 8 parameters for other scalar predictors. These 17
338 predictors are referred to as All-variable set. All computations (FLM model training, PC analysis)
339 are implemented with the R package *fda.usc* (Febrero-Bande and De La Fuente, 2012).

340 2.5.2. GAM

341 We successively feed a GAM (hereafter called Lagged GAM (LGAM)) with point wise time
342 series values, from DC, DMC and NDVI, with models evaluated separately for time-lags τ ranging
343 from -185 to 0 with a 5-day step in addition to static predictors., following the equation:

$$\begin{aligned}
RBR_i = & \alpha'' + g_{NDVI}(NDVI_i(\tau)) + g_{DMC}(DMC_i(\tau)) \\
& + g_{DC}(DC_i(\tau)) + NLM_i + \epsilon_i''
\end{aligned} \tag{6}$$

344 with : $\alpha'' \in \mathbf{R}$, the intercept; $i = 1, \dots, N$, N size of the sample; $\epsilon_i'' \sim \mathcal{N}(0, \sigma''^2)$, independent
345 for different i ; $\tau \in [-185 ; 0]$, time-lag (number of days before fire); g_k , $k \in \{NDVI, DMC, DC\}$,
346 smooth function; NLM_i a non-linear additive combination of scalar predictors.

347 As benchmark model, we trained, and tested a GAM fed with measured pre-fire remote sensing
348 data and day-of-fire DC and DMC in addition to static predictors. Both models are fitted using a
349 Gaussian distribution of the response variable with the R package *mgcv* (Wood, 2011). We use
350 REML for automatic smoothing parameter optimization and activate the internal variable selection
351 to identify and remove non relevant predictor variables (Marra and Wood, 2011).

352 2.6. Train-test procedure of the models

353 In this section, we describe the procedure developed to evaluate the predictive performance of
354 the above models.

355 *2.6.1. Splitting procedure for training and test datasets*

356 Prediction of fire severity requires that the training and test datasets are independent in time
357 and space. The entire fire–LC dataset is randomly split into a training and test dataset according
358 to a 90-10% ratio and considering the location and time of each fire. For a given fire, all its fire–
359 LC pairs are either in the training dataset or in the test dataset. To increase the variability of the
360 training dataset when the previous split is repeated, only 75% of the initial training dataset is kept
361 (remaining fire–LC are unused) in the final training dataset.

362 *2.6.2. Optimal time depth/time-lag selection and best predictor selection*

363 For both LGAM and FLM, based on time-lagged data and time series as inputs respectively,
364 we select the optimal time-lag and the optimal time depth that minimize a prediction accuracy
365 measure. In addition, for FLM, given the initial high number of variables (All-variables set: 17
366 variables) and the comparatively small size of our dataset (179 fire–LC), variable selection was
367 beneficial to avoid overfitting and to catch the most relevant predictors among PC-scores and
368 scalar variables. For GAM/LGAM, the automatic choice of smoothing hyperparameters, together
369 with the internal variable selection to identify unnecessary predictor variables (Marra and Wood,
370 2011), avoids overfitting.

371 Whatever the modelling approach, we first randomly split the entire dataset 10 times, using
372 the method described above in 2.6.1, so that each fire LC is exactly once in a test dataset. Then
373 we train 10 different models according to the different training datasets and we get one prediction
374 per Fire–LC. We repeat this first step 10 times so that each Fire–LC appears exactly 10 times in a
375 test dataset. This approach, known as 10-fold cross validation, is repeated 10 times. Overall, this
376 approach results in 100 trained models that provide exactly 10 test predictions for each Fire-LC.
377 These train/test split and training procedures are repeated for each time depth varying between
378 -185 and -15 days and each time-lag varying between -185 and 0, with a 5-day time step, for
379 FLM and LGAM, respectively. The minimum time series length for FLM is set to 15 days for
380 consistency with the time series approach in comparison with the scalar approach; this is motivated
381 by the average shift between pre-fire satellite overpass and fire date of mean[standard deviation]=
382 6.5[5.5] days.

383 We further put into practice the optimal time depth selection for FLM by considering the
 384 Root Mean Square Error ($RMS E_{test}$), computed at each time depth between the measured RBR
 385 and the predicted RBR for each of the 100 test datasets (Li et al., 2023). For every time depth $\delta \in$
 386 $[-180; -20]$, the average $\overline{RMS E_{test}}(\delta)$ and standard error $se_{test}(\delta)$ of $RMS E_{test}(t)$, $t \in [\delta - 5; \delta + 5]$,
 387 are computed. The optimal time depth δ_{opt} is the maximum δ where the minimum $\overline{RMS E_{test}}$ is
 388 reached. To account for uncertainty in the choice of optimal time depth, we further note δ_{min} the
 389 minimum time depth such as for all $\delta_{min} \leq \delta \leq \delta_{opt}$ we have $\overline{RMS E_{test}}(\delta) \leq \overline{RMS E_{test}}(\delta_{min}) \leq$
 390 $\overline{RMS E_{test}}(\delta_{opt}) + 1.96 se_{test}(\delta_{opt})$, and we note δ_{max} the maximum time depth such as for all
 391 $\delta_{opt} \leq \delta \leq \delta_{max}$ we have $\overline{RMS E_{test}}(\delta) \leq \overline{RMS E_{test}}(\delta_{max}) \leq \overline{RMS E_{test}}(\delta_{opt}) + 1.96 se_{test}(\delta_{opt})$.
 392 We respectively define for LGAM the optimal time-lag τ_{opt} , τ_{min} and τ_{max} using the same method-
 393 ology.

394 Finally, for FLM only, the cumulated number of times that a predictor variable is selected for
 395 the time depths the interval $[\delta_{opt}, \delta_{max}]$ is computed. Only variables selected at least 1 time out of
 396 2 (both static scalar variable and PC scores), named FLM-selected variables set, are kept in the
 397 final FLM model.

398 2.6.3. Selection of optimal model

399 Whatever the modelling approach, we follow the same train/test split procedure as in 2.6.2
 400 (10-fold cross validation repeated 10 times), that results in 100 trained models and exactly 10
 401 test predictions per fire LC. For all the considered FLM, LGAM and GAM, both All-variable
 402 set and FLM-selected variables set are used as input. GAM takes as input the day-of-fire DC,
 403 DMC and ISI and immediate pre-fire measured NDVI. LGAM and FLM take as input time-lagged
 404 predictors or times series, respectively, evaluated at the optimal time-lag or optimal time depth. For
 405 FLM, when the All-variable set is used, no variable selection is performed, even if we select the
 406 corresponding optimal time depth following the procedure previously described (see 2.6.2). For
 407 every repetition of the 10-fold cross validation, the predicted RBR dataset that contains exactly
 408 one RBR prediction of each Fire-LC is then evaluated against measured RBR. Performance scores
 409 used here are the RMSE and the coefficient of correlation (R). Then the R/RMSE are averaged.
 410 For every training dataset the same performance scores and Bayesian Information Criteria (BIC)

411 are computed and then averaged. Finally, the prediction accuracies are compared first by set of
412 variables for a given modelling approach (GAM, LGAM or FLM) and then between modelling
413 approaches (GAM, LGAM and FLM).

414 *2.6.4. Exploration of optimal models*

415 For all the models herein implemented the prediction accuracies (RMSE, R) are also computed
416 by canopy structure type (see Table 1) to assess group-specific performance. For FLM, all the
417 estimates provided by trained models are recorded to compute a mean and 95% confidence interval
418 of the estimated weighting function β for each functional predictor and of coefficient estimates for
419 each scalar predictor. For LGAM/GAM and every trained model, we record the smooth functions
420 of each predictor as well as their effective degrees of freedom (EDF) as a proxy for the degree of
421 non-linearity to compute a mean value and a 95% confidence interval. An EDF of 1 is interpretable
422 as a linear relationship, an EDF greater than 1 and lower than 2 is a slightly non-linear relationship,
423 and an EDF greater 2 indicates a strong non-linear relationship (Hunsicker et al., 2016; Zuur et al.,
424 2009).

425 *2.6.5. Importance of predictors*

426 We define the importance of a predictor as the amount of change of predicted RBR when this
427 predictor is randomly shuffled in the test dataset. To estimate the predictor importance, we follow
428 the same procedure as for best model selection (see 2.6.3), except that for a given predictor, the test
429 dataset is randomly shuffled while the others predictors are not (permutation predictor importance).
430 The relative increase in the RMSE between the predicted and measured RBR, in comparison to the
431 unshuffled test dataset RMSE, defines the variable importance (Breiman, 2001; Kaneko, 2022).

432 **3. Results**

433 Results of the intercomparison between the three (GAM, LGAM and FLM) RBR models are
434 presented in Section 3.1. In Section 3.2 the importance of each predictor and their impact on
435 model predictions are presented.

436 3.1. Model performance comparison

437 3.1.1. Selection of predictor set and input parameters

438 Based on the selection methodology of 2.6.2, all the predictors kept in the FLM-selected vari-
439 ables set are hereafter presented. The selected functional predictors are NDVI, DMC and DC;
440 the selected PC-scores are C_{NDVI1} , C_{NDVI2} , C_{DMC1} , C_{DMC3} and C_{DC2} . Moreover, 3 out of 9 scalar
441 predictors are selected: DOY, ISI and latitude. Predictor selection divides the number of variables
442 in FLM models by more than 2 (8 out of 17). We note that all fuel proxies (NDVI, DMC, DC)
443 were selected, while more indirect fuel proxies (elevation, slope) are not. One location predictor
444 (latitude) was selected. Finally, meteorological variables of the year preceding the year of the fire
445 were not selected, suggesting that the year of the fire provides more valuable information.

446 Figure 2 shows the optimal time-lag and optimal time depth for LGAM and FLM respectively,
447 for both sets of input predictors separately. When the All-variables set is used, FLM reaches a
448 minimum $RMS E_{test}$ for a time depth $\delta_{opt} = -70$ days while LGAM gets a minimum $RMS E_{test}$
449 for a time-lag τ_{opt} equal to -80 days (see Figure 2). When the FLM-selected variables set is
450 used, FLM reaches a minimum $RMS E_{test}$ for a time depth $\delta_{opt} = -65$ days while LGAM gets a
451 minimum $RMS E_{test}$ for a time-lag τ_{opt} equal to -25 days (see Figure 2). Except for the LGAM
452 built with the set of FLM-selected variables, the intervals $[\delta_{min}, \delta_{max}]$ and $[\tau_{min}, \tau_{max}]$ intersect each
453 other. Neither the satellite's mean overpass time before fire (-6.5 days) nor the day of the fire (i.e.
454 0 days) fall within these intervals, suggesting a significant effect of time-lagged variables.

455 Whatever the model, slightly better accuracies are reached when the set of FLM-selected vari-
456 ables is used than when the set of All-variables is used. Figure 3 (respectively Figure A.1) presents
457 the boxplot of accuracy predicitions (R) (respectively RMSE) separately for the All- and FLM-
458 selected variables and for the test and training datasets. More specifically, for each of the 3 models,
459 the median R for the FLM-selected variables set and test dataset, is equal to or greater than for
460 the All-variables set, even if the interquartile ranges overlap, except for FLM (see Figure 3). In
461 addition, by comparing the test RMSE between the set of All variables and that of FLM-selected
462 variables, GAM, LGAM and FLM significantly reduce the RMSE by 1.5%, 3.0% and 8%, respec-
463 tively. Thus, variable selection allows us to build more parsimonious models, avoiding overfitting,
464 even when automatic variable selection is activated for GAM and LGAM models. Consequently,

465 we will hereafter consider only the (GAM, LGAM and FLM) models built with the set of FLM-
466 selected variables.

467 Throughout, a substantial drop of prediction accuracy measures is observed when comparing
468 training and test results in Figure 3 for models built with the set of FLM-selected variables. This
469 drop can be attributed to two interacting factors: the relatively larger number of variables and hy-
470 perparameters in all models, and the relatively small number of observations. While the decrease
471 (increase) in R (RMSE) only reaches 0.06 (0.006) for FLM, it reaches 0.19(0.015) and 0.23(0.018)
472 for LGAM and GAM respectively. Therefore, all models show overfitting, but the FLM-based ap-
473 proaches are least prone to overfitting, and working with FLM-selected variables further alleviates
474 overfitting in all models. The relatively good training-based prediction scores of GAM and LGAM
475 are misleading, and only test-based scores will be discussed in the remainder of the paper.

476 3.1.2. Performance comparison of GAM, LGAM and FLM

477 FLM achieves better accuracies than LGAM, and both models outperform the state-of-the-
478 art GAM. FLM reaches $R=0.68/RMSE=0.057$ and LGAM reaches $R=0.60/RMSE=0.063$, while
479 GAM only achieves $R=0.52/RMSE=0.069$. Both boxplots (see Figure 3 and Figure A.1)) show
480 that differences between models are significant. These results imply that RBR can be predicted
481 with good accuracy at another location and time on the scale of fire-LC when considering the time
482 series of remote sensing and meteorological data prior to a fire.

483 FLM obtains a lower BIC (-328) than LGAM (-322) and GAM (-313), suggesting a better com-
484 promise between parsimony and precision with regard to training. However, we emphasize that
485 the three model classes (GAM, LGAM, FLM) each possess a relatively large number of degrees
486 of freedom but with respect to quite different data features, such that the differences in prediction
487 performance are largely due to model structure and not only model complexity. The additional
488 lag-parameter of LGAM leads to clear superiority over the classical GAM, and the use of the in-
489 formation describing the shapes of time series curves in FLM brings significant performance gains
490 in comparison to the nonlinearities available in GAM and LGAM.

491 The improved accuracy of FLM over LGAM for RBR prediction is also consistently observed
492 in the separate analysis for different canopy structure type. Table A.1 presents the R and RMSE

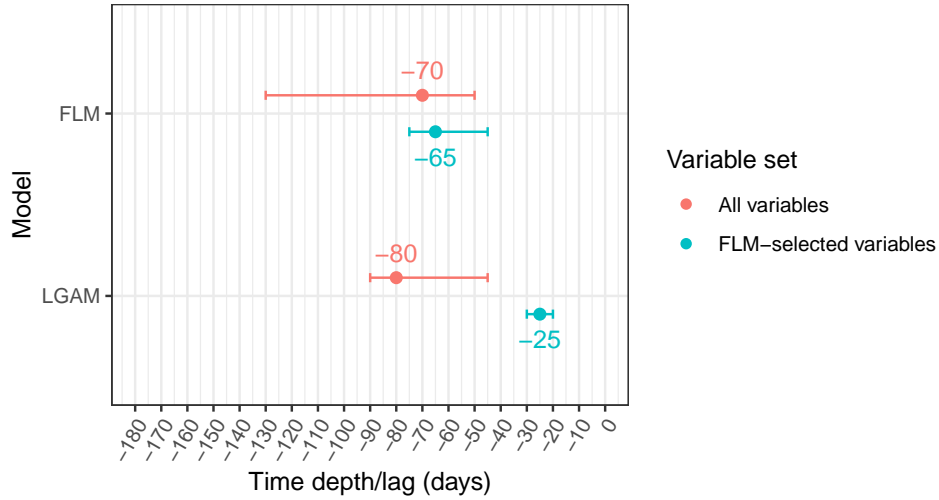


Figure 2: Intervals $[\delta_{min}; \delta_{max}]$ and $[\tau_{min}; \tau_{max}]$ and point set in δ_{opt} and τ_{opt} , respectively for FLM and LGAM, per variable set. The x-axis is the number of days before fire

493 between predicted and measured RBR, according to the canopy structure type. The best accuracies
 494 of FLM are achieved for shrublands, open canopy structure type and finally closed canopy struc-
 495 ture type. The same order is achieved by LGAM/GAM, which have lower prediction accuracies
 496 than FLM. Remotely sensed vegetation indices such as the NDVI are sensitive to the upper visible
 497 part of the canopy, while fire is driven by and affected both understory and overstory, and so is
 498 RBR. Consistently, for open canopy forests and shrublands, the prediction is good. Conversely,
 499 accurately predicting RBR over closed canopy forest is difficult since NDVI does not catch under-
 500 story information.

501 3.2. Assessing the importance of predictors and their impact on RBR predictions

502 We present each variable by decreasing order of importance in FLM modelling, starting with
 503 DMC (3.2.1) followed by NDVI (3.2.2), and DC 3.2.3) and ending with the scalar variables (lati-
 504 tude, DOY, ISI) (3.2.4).

505 3.2.1. DMC

506 Figure 4 shows the importance of FLM-selected predictors (as defined in 2.6.5) per modelling
 507 approach. DMC achieves an importance in FLM of 34%) for RBR predictions. The interpretable

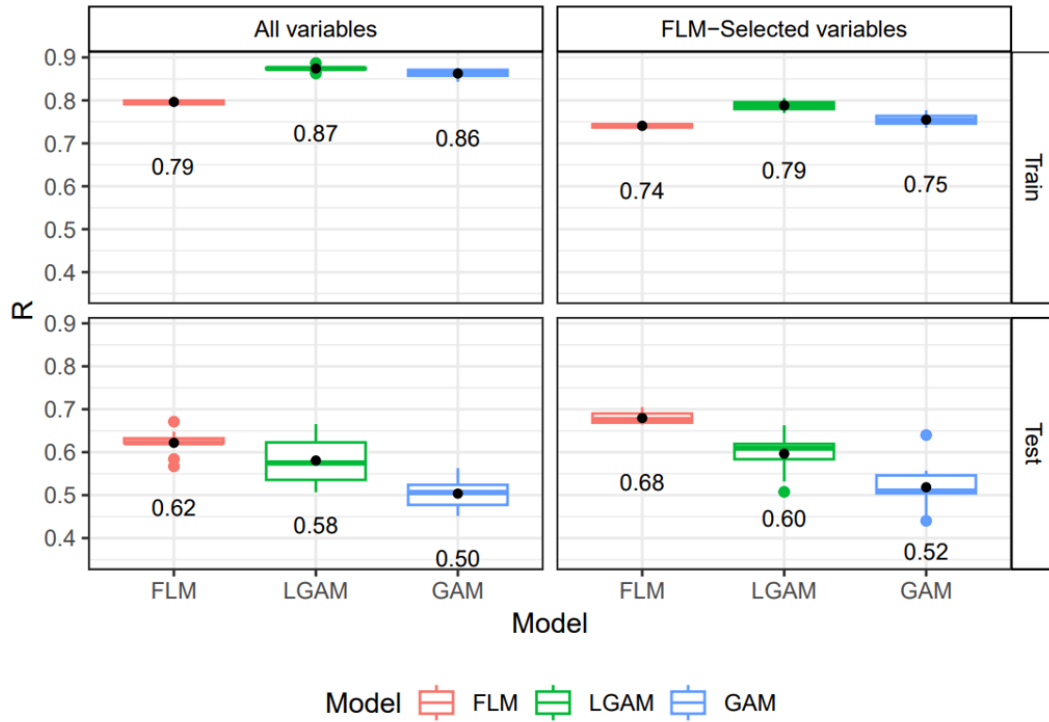


Figure 3: Boxplots of prediction accuracy (R) per modelling approaches, variable set and dataset. The black point and the numerical value below each boxplot is the mean R.

508 function that illustrates this result is the estimated weighting function β_{DMC} : it reflects the tempo-
 509 ral weighting of DMC times series of length $|\delta_{opt}|$. Figure 5 a and b show the estimated weighting
 510 functions β corresponding to the time series of each predictor (NDVI, DMC and DC). The esti-
 511 mated weighting function β_{DMC} positively weights DMC values that are below the pointwise mean
 512 DMC before -45 days (particularly at time -55 days), and above the pointwise mean DMC in the
 513 interval [-45;-8] days, with a strong weight at $t=-20$ days (see Figure 5 a). From -8 days to day of
 514 fire, the weight is almost zero.

515 The optimal time-lag of $\tau_{opt} = -25$ days in LGAM matches the time when β_{DMC} strongly
 516 weights the high DMC values. Figure 6 (respectively Figure A.2) presents the estimated partial ef-
 517 fects of smoothed functions of LGAM (respectively GAM) for the FLM-selected variables. DMC
 518 reaches an importance of 16% in LGAM and provides a nearly linear and increasing smooth func-
 519 tion (EDF=1.1). The similar partial effects of smoothed functions and a lower importance are

520 achieved for GAM.

521 3.2.2. *Impact of NDVI*

522 In FLM, NDVI has an importance of 32% (see Figure 4). The curve β_{NDVI} is strictly decreasing,
523 with positive values in the interval [-65;-20] days and negative values in the interval [-20;0] days
524 (see Figure 5 a). Thus, it positively weights NDVI values that are greater than the pointwise mean
525 NDVI before -20 days, and gives almost half the weight to values that are less than the pointwise
526 mean NDVI after -20 days. Consequently, high RBR values are achieved for NDVI time series
527 that decrease more rapidly than the mean NDVI time series, and that have a high NDVI 65 days
528 before the fire and low a NDVI on the day of the fire.

529 Given the intrinsically temporal nature of this behaviour related to the NDVI dynamics and the
530 corresponding shape of its time series, such results cannot be captured within the framework of
531 static LGAM/GAM. Both LGAM and GAM provide a nearly linear increasing smooth function
532 (EDF=1.1, see Figure 6 and Figure A.2) of absolute values of NDVI at $t = \tau_{opt} = -25$ days
533 and immediately before fire respectively. Even if NDVI is the second most important variable in
534 LGAM and GAM modelling, its importance is smaller than for FLM (see Figure 4). This partly
535 explains the gap in prediction accuracies between LGAM, GAM and FLM.

536 3.2.3. *Impact of DC*

537 Similar to DMC, DC is a meteorological code that is evaluated using the same input data (air
538 temperature, 24h-cumulative rainfall), except that DMC also takes RH into account. DC is the
539 third most important variable, at 11% (see Figure 4). The estimated curve β_{DC} is a decreasing
540 function of time and positively weights DC values that are greater than the pointwise mean DC
541 before -35 days and less than the pointwise mean DC after -35 days (see Figure 5 a and b).

542 Average DC values ([300,700]) maintained between -65 to 0 days are linked to a high severity
543 rate. In contrast, rapid DC increases leading to high DC values on the day of fire are linked
544 to a low RBR (see Figure 5a). This situation can be encountered in places where precipitation
545 is low and/or air temperature high but without extreme conditions for several months (Ruffault
546 et al., 2018a; Van Wagner et al., 1987). Between -65 and 0 days, every DC function is increasing,
547 meaning there was no significant precipitation in this time interval (Van Wagner et al., 1987), and




Figure 4: Importance of FLM-selected variables per model.

548 suggesting that meteorological water inputs for living fuel were low, whatever the fire considered.
 549 Given that DC change time is 52 days, this result is consistent with a low long-term soil water
 550 availability and high air temperature influencing summer living fuel activity (Piedallu et al., 2019).
 551 These results are consistent with the LGAM/GAM results, which show that DC reaches very low
 552 importance in LGAM/GAM (see Figure 4) and partial effects are decreasing and almost zero (see
 553 Figure 6 and Figure A.2) when DC is evaluated between -35 days and the day of the fire.

554 3.2.4. Impact of the other static variables: latitude, DOY and ISI

555 Latitude has an importance of 6%, 22% and 16% for FLM, LGAM and GAM respectively (see
 556 Figure 4). Such a difference is mainly explained by the strongly non-linear influence of latitude
 557 on RBR in LGAM/GAM (EDF=4.3/3.9, see Figure 6 and Figure A.2). Latitudes under $42^{\circ}N$ and
 558 above $43.3^{\circ}N$ involve low RBR, while latitudes between $42^{\circ}N$ and $43.3^{\circ}N$ involve high RBR.
 559 This interval encompasses the central French Mediterranean area, where the vast majority of fires
 560 occurs along the sea (see Figure 1). Such a discrepancy in importance between LGAM/GAM and
 561 FLM suggests that either latitude is a proxy for an effect that is already accounted for through time

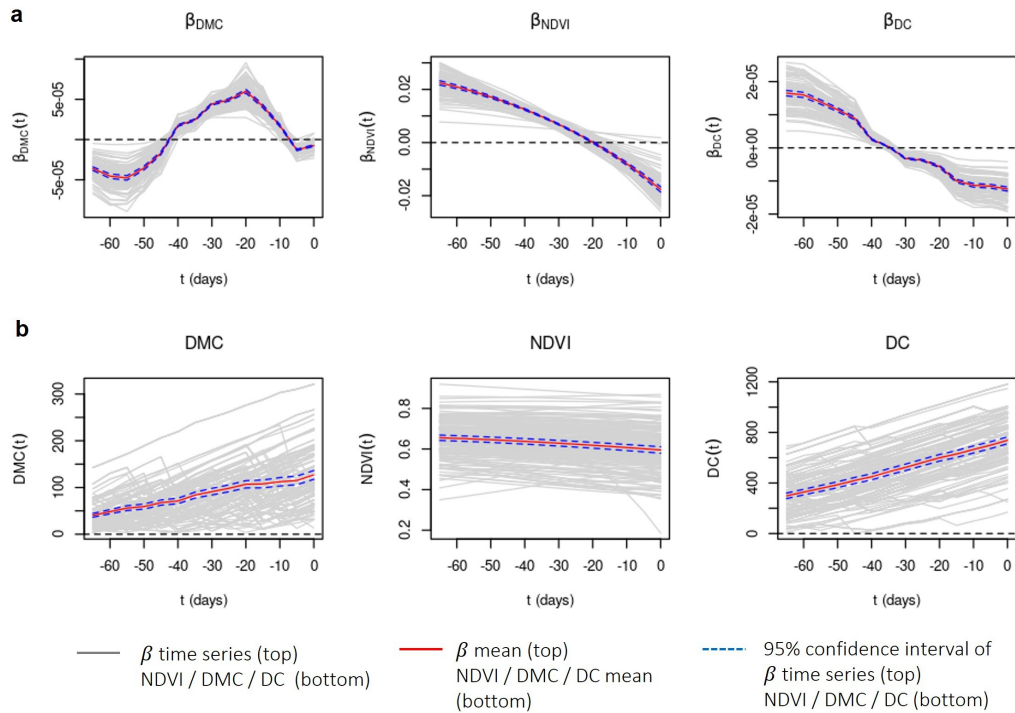


Figure 5: Time series of a) weighting functions β for DMC, NDVI and DC variables and b) time series of DMC, NDVI and DC (bottom) separately. $t = 0$ matches the day of fire. Grey lines refer to the 100 weighting functions (top) and the 179 DMC, NDVI and DC time series per Fire-LC (bottom).

562 series in FLM, or, due to the linear model, FLM is unable to capture this non-linear influence. We
 563 point out that simply including latitude as an additional nonlinear smooth effect in FLM (i.e., in a
 564 FPCR-GAM hybrid model) does not improve test-based prediction performance ($R=0.67[0.053]/$
 565 $RMSE = 0.059[8.1e-3]$). Therefore, further studies are needed to understand this a priori area-
 566 specific behaviour and the interactions between latitude and other predictor variables to possibly
 567 integrate it into an improved model.

568 DOY has a low importance for FLM, LGAM and GAM at 5%, -1% and 2%, respectively (see
 569 Figure 4). For FLM, LGAM and GAM respectively, positive coefficient estimate (0.00049) and
 570 increasing smooth functions (see Figure 6 and Figure A.2) and show a positive correlation between
 571 DOY and RBR. We suppose that this non-biophysical predictor explains a seasonal phenomenon
 572 that neither NDVI nor DC/DMC explain.

573 ISI has an importance of 4% for FLM (see Figure 4) and shows a counterintuitive negative

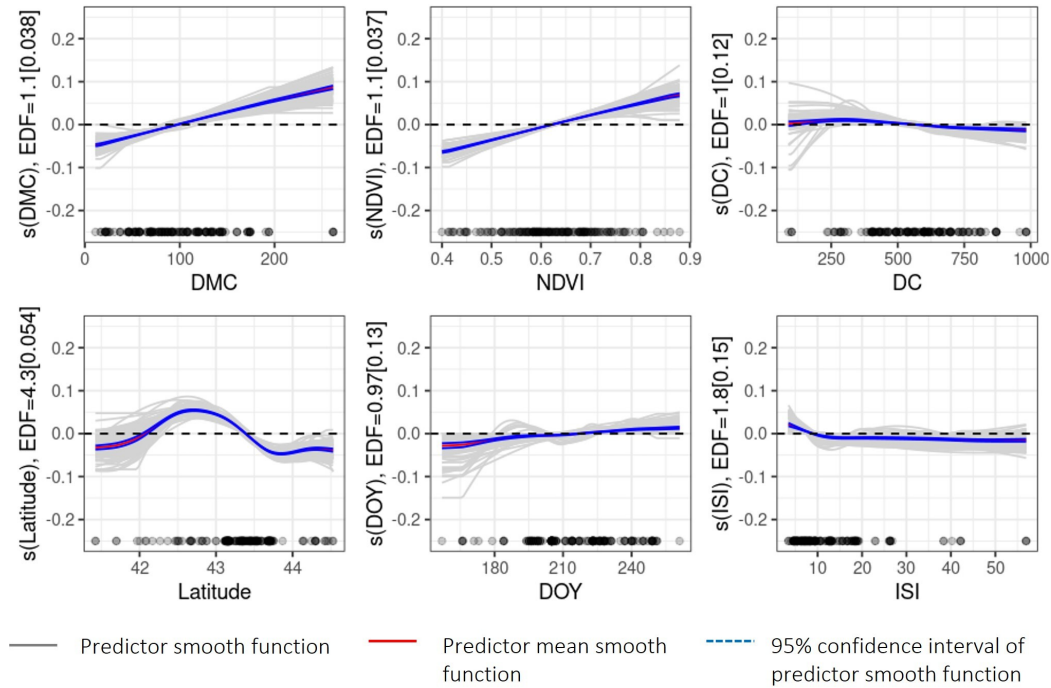


Figure 6: Mean partial effects of smooth functions for LGAM at $\tau_{opt} = -25$ days. y-label provide the mean EDF and its standard error. Grey lines refer to the 100 smooth functions.

574 effect on RBR since its mean coefficient estimate is negative (-0.0012), while its importance for
575 LGAM/GAM is almost 0. ISI is a proxy for the rate of spread without the influence of variable
576 quantities of fuel fire (Van Wagner et al., 1987). At decametric spatial scale, wind speed (Viedma
577 et al., 2020) or rate of spread (Viedma et al., 2014) is one of the controlling factors of FSI. In fact,
578 at fine spatial scale, rate of spread is a function of the relative position of the pixel in relation to the
579 advancing flame front (leading, flanking, receding, etc). Thus, at our coarse spatial scale, Fire-LC
580 ISI may not be consistent. In addition, as already pointed out by (Taylor et al., 2021), our weather
581 data is daily and has a resolution of 8 km, whereas fire weather conditions can vary from hour to
582 hour and over short distances in steep terrain (Viedma et al., 2020).

583 4. Discussion

584 4.1. Model predictive accuracies

585 In our study, we used time series of pre-fire optical remote sensing data and meteorological
586 indices to predict fire severity (RBR). We show that the use of time series significantly improves
587 prediction accuracy (R, RMSE) compared to the use of immediate pre-fire values or time-lagged
588 point values. Our evaluation of prediction accuracy allows for more robust results and conclusions
589 as the test dataset is independent in time and space from the training dataset. To date no such study
590 has been carried using pre-fire time series and the test/train split evaluation procedure. Parks et al.
591 (2018a) used the same train/test split procedure with immediate pre-fire data and scalar summaries
592 of past conditions. With two classes of RBR ($RBR < 0.298$ and $RBR \geq 0.298$) in the western US
593 forests, they reached an area under curve of 0.72. A result is that a posteriori classification of RBR
594 predictions by FLM, using the same classes, provides an accuracy of 98%. However, one must be
595 very careful with this result because our dataset is not equally balanced between the two classes
596 (90% of our Fire-LC is classified as $RBR \geq 0.298$). More recently, in the Mediterranean area,
597 Fernández-García et al. (2022) predicted DNBR at a spatial resolution of 20 m with data remotely
598 sensed immediately before the fire and achieved a correlation (R) of 0.49 on the test dataset.

599 4.2. Optimal time depth

600 Our study shows that knowledge of two months (65 days) of pre-fire fuel dynamics improves
601 fire severity index prediction. Longer or shorter time series or point wise time values are not
602 useful and may introduce additional noise into the prediction. This finding is consistent with
603 studies of fire occurrence or size using similar time frames, as there is a lack of reference in the
604 area of fire severity research. Vega-Nieva et al. (2024) found that a period of 50 days (selected
605 from candidates in the range of 10-90 days for an accumulated fuel dryness index) was optimal
606 for predicting fire occurrence in Mexico; Riley et al. (2013) found that metrics based on one to
607 three months of weather data, such as monthly precipitation totals, had strong correlations with
608 both total area burned and number of large fires. The optimal time depth of 65 days may capture
609 live fuel moisture dynamics – as a consequence of accumulated drought and/or antecedent water

610 balance – that have been highlighted in fire occurrence prediction (Riley et al., 2013; Vega-Nieva
611 et al., 2024)

612 4.3. Impact of the most important predictors on RBR

613 We show that predictors using time series are the most important (DMC, NDVI then DC)
614 compared to the scalar predictors. FLM modelling allows us to physically interpret the time series
615 variations that lead to high or low fire severity.

616 Our results provide a better understanding of the DMC dynamics before fire. The DMC de-
617 creases logarithmically with rainfall (which is taken into account if it exceeds 1.5 mm) and is a
618 linearly increasing function of air temperature and a decreasing function of RH (Van Wagner et al.,
619 1987). A fast increase of DMC is hence the result of either high air temperature, or low RH or
620 both. Thus, β_{DMC} positively weights fires subjected to strong meteorological forcing for 35 days
621 (-55 to -20 days before the fire (see Figure 5)), a period of time that is consistent with the DMC
622 change time (12 days) (Van Wagner et al., 1987). FLM and LGAM show that, contrary to other
623 studies on activity of large fires (Barbero et al., 2019) and burnt area (Maffei and Menenti, 2019),
624 short-term DMC values (from -8 days to the day of the fire) do not strongly influence RBR. This
625 result is supported by the low importance (3%) of DMC in GAM (see Figure 4). Our interpretation
626 is that, given the DMC change time (12 days) (Van Wagner et al., 1987), this index is not able to
627 influence the RBR in such a short time span.

628 Our results confirm other studies that suggest a strong positive impact of NDVI on FSI (Parks
629 et al., 2018a; Taylor et al., 2021). Furthermore, they provide insights in the NDVI pre-fire dynam-
630 ics leading to high RBR. A low $NBR_{prefire}$, which is highly correlated to pre-fire NDVI ($R=0.94$
631 in our dataset), is either the result of a low pre-fire dead/living biomass all year long, or which is
632 the result of a decrease in the amount of living/wet fuel (Chuvieco et al., 2002; García et al., 2020;
633 Yebra et al., 2013). However, $NBR_{postfire}$ is sensitive to postfire disturbances (ash, etc.) (Hudak
634 et al., 2007; Kokaly et al., 2007; Lewis et al., 2021) which are the result of fire influence on living
635 and dead fuel (combustion, scorching, etc.) (Jain and Graham, 2007). Consistently, since NDVI
636 time series are a proxy for live/wet fuel (Chuvieco et al., 2004, 1999; González-Alonso et al.,
637 2006; Zhu and Liu, 2015), NDVI that is decreasing faster than average may be the result of an

638 increase over time in dead or dry fuel (Brodrick and Asner, 2017; Pettorelli et al., 2005), which
639 then induces more fuel consumption (Andrews, 2018).

640 Regarding other studies that establish a positive correlation between short-term/day-of-fire DC
641 values and severity (Fang et al., 2015) (only for $DC < 180$), our results may seem contradictory.
642 However, in our case, with the exception of 4 fires, the DC on the day of the fire were lower than
643 the average DC, and were between 400 and 740, which were already high values. For instance,
644 Californian mega-fires of 2018 started for DC in forest above 400 (Kang et al., 2023), and (Pel-
645 lizzaro et al., 2007) defines $DC=400$ as the value that could be critical for ignition potential of
646 two shrub species of northwest Sardinia. More specifically, all studies relating DC to fuel mois-
647 ture content in the Mediterranean area, show that from $DC=600-800$, the fuels become as dry as
648 possible, i.e. they reach a saturation level (Field et al., 2015; Pellizzaro et al., 2007; Viegas et al.,
649 2001).

650 NDVI variations reflect the interaction between fuel and weather because NDVI directly mea-
651 sures a surface state at high spatial resolution (fuel biomass and greenness) and thus the live fuel
652 response to meteorological forcing. The longer-term variable DC is an index that only reflects
653 meteorological conditions, particularly drought, typically calculated from data available at coarser
654 spatial resolution. This may explain the greater importance of NDVI compared to DC when ex-
655 plaining RBR, even though NDVI variations (possibly delayed) are partly a consequence of me-
656 teorological forcing. However, the fact that DC remains in the set of variables selected by FLM
657 implies that it brings additional information that is not included in NDVI variations. This suggests
658 that the combined use of meteorological and remotely sensed data is important in the field of fire
659 severity prediction and, more generally, in the field of fire risk outcomes modelling. Indeed, fire
660 risk models and indices are mainly based on meteorological data, with the exception of the Fire
661 Potential Index (Burgan et al., 1998), which combines both information.

662 *4.4. Example of application to two contrasted fires*

663 To illustrate the previous results, two fires named as fire A and fire B are selected for their
664 contrasted overall severity. More specifically, these two fires show different temporal dynamics
665 in terms of NDVI and DC, and almost the same temporal dynamics in terms of pre-fire DMC.

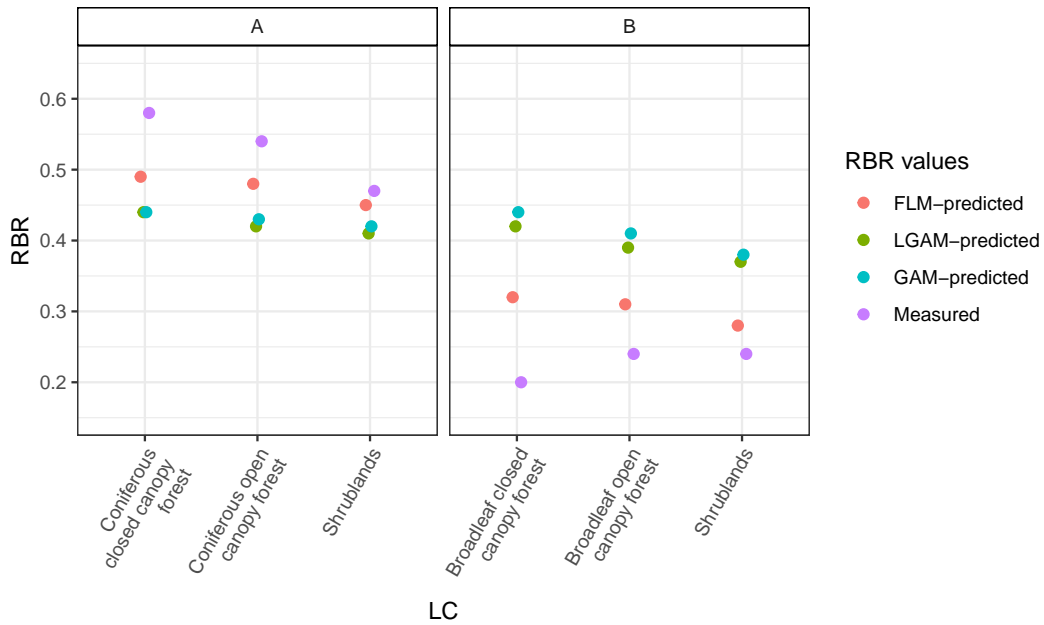


Figure 7: RBR values, measured or predicted by the different models, per fire and LC.

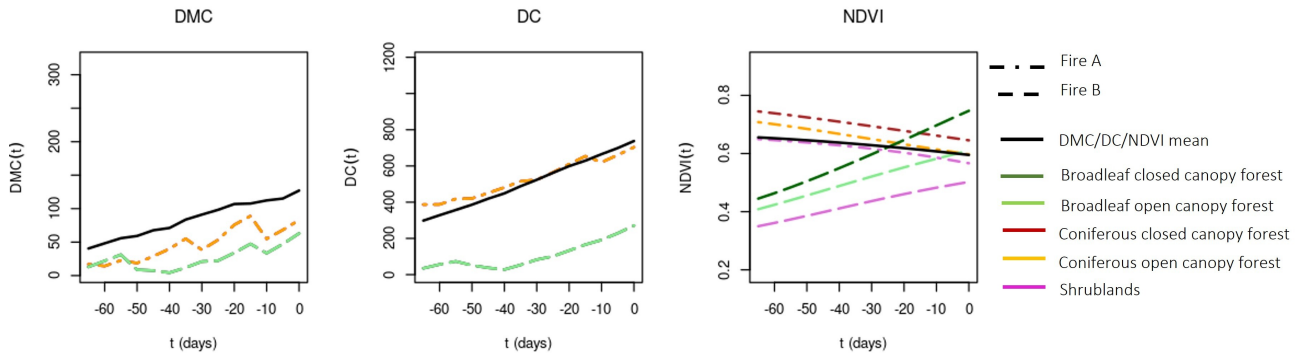


Figure 8: Predictor time series for the two studied fires A (high severity) and B (low severity); see 4.3 for details. Time series of DMC, NDVI and DC per Fire-LC, and mean (all dataset) time series of DMC, NDVI, DC.

666 These examples would allow a better understanding of the important role of pre-fire time series in
 667 predicting fire severity. Fire A took place the 3rd, July 2021 (DOY=184, ISI=4.72, latitude=43.16).
 668 Its three LC classes have RBR measured values larger than the third quartile of all the dataset.
 669 Fire B occurred the 15th, June 2017 (DOY=166, ISI=4.43, latitude=43.71). It is one of the less
 670 severe fires in the dataset. Figure 7 presents the measured RBR and the mean predicted RBR from
 671 the three (FLM, LGAM and GAM) models, for each fire-LC separately. Figure A.3 shows the

672 measured RBR map (a), the FLM mean RBR prediction map (b), and the LC map (c) for fire A
673 and B separately. All the models underestimate the RBR of fire A (high severity) and overestimate
674 the RBR for fire B (low severity), for all LC classes (see Figure 7 and Figure A.3). However, FLM
675 achieves the best results for both fires and every LC, by reducing the absolute error committed by
676 the best GAM/LGAM by 35 to 70%.

677 Figure 8 presents the pre-fire DMC, NDVI and DC times series for each of the 6 fire-LC and
678 the fires A and B. Due to the coarse resolution of SAFRAN data, all fire-LC of the same fire
679 have the same DC and DMC values. For both fires, the DMC values are lower than the pointwise
680 mean DMC, indicating a relatively low meteorological forcing prior to the fires. DC values are
681 more contrasted. Fire B DC is very low, with values below the mean pointwise DC during the 65
682 days preceding the fire. Fire A DC time series have a pattern that is positively weighted by the DC
683 weighting function: between -65 days and -30 days, DC values are higher than the pointwise mean,
684 while DC values between -30 days and 0 days are lower than the pointwise mean (see 3.2.3). The
685 most contrasting pre-fire temporal dynamics are found for NDVI time series. The NDVI values
686 of the three fire-LC of Fire B increase with time and are lower than the pointwise mean NDVI 65
687 days before the fire. For Deciduous Close and Open canopy forest, the NDVI is higher than the
688 pointwise mean NDVI on the day of the fire, whereas Shrublands NDVI values remain lower than
689 the pointwise mean NDVI. These temporal patterns lead to a negative impact of NDVI on RBR
690 (see 3.2.2). On the contrary, the NDVI time series of the three fire-LC of fire A show a faster-
691 than-mean decrease and are higher than the mean 65 days before the fire and lower than the mean
692 (for two LC) on the day of the fire. This pattern leads to a positive impact of NDVI on RBR (see
693 3.2.2). Therefore, although the meteorological conditions do not clearly distinguish the RBR of
694 fires A and B, the NDVI time series provide a better understanding of the pre-fire conditions and
695 the contrasting RBR values between the two fires. We suggest that taking the temporal information
696 into account explains the difference in prediction between FLM and GAM/LGAM.

697 4.5. Perspectives

698 Current advances in optical/thermal remote sensing over forests (Penot and Merlin, 2023) and
699 the future thermal mission (TRISHNA) could remove the spatial limitations about the meteoro-

700 logical indices. The high spatial and temporal resolution of thermal data would give access to
701 site-specific estimates of evapotranspiration/water stress in conjunction with a physical model of
702 the moisture content of live fuels (Ruffault et al., 2023). In addition, using non-linear functional
703 models may bring valuable improvements to the results of this study. Finally, the use of physical
704 models of fire behaviour (Andrews, 2018) and high resolution input data (Sebbar et al., 2023; Wa-
705 genbrenner et al., 2016), would bridge the gap between FSI models that operate at both coarse and
706 fine scales, providing operational products for both land managers and fire-fighters.

707 **5. Conclusion**

708 To date, accurate prediction of remotely sensed fire severity indices, such as RBR, from pre-
709 fire optical and meteorological data remains a challenging task. Taking into account the temporal
710 dynamics of pre-fire fuel proxies has not yet been explored. To fill the gap, this study is based on
711 the use of widely available pre-fire time series of remote sensing and meteorological data in FLM
712 and time lagged data in LGAM to predict RBR at fire–LC scale. More specifically, the objectives
713 are: 1) to quantitatively assess the usefulness of time series or time lagged data in statistical models
714 to predict RBR, 2) to assess the optimal time depth/lag and the best predictors set to predict RBR.

715 As a first assessment, the use of times series / time-lagged data in FLM and LGAM models,
716 improves the results obtained by the benchmark model (GAM). In addition, a time depth of 65
717 days before the fire allows FLM to achieve the best prediction accuracies, while a time-lag of 25
718 days for RBR predictions allows LGAM to improve the GAM prediction accuracies. The two
719 most important selected predictors are DMC and NDVI for FLM, followed by DC, which are all
720 variables related to fuel behaviour. The faster-than-average decrease in NDVI, starting from high
721 values 65 days before fire, leads to large RBR values: the process of drying/dying of living fuel
722 before fire leads to large RBR. Consistently, the DMC time series that increase faster than average
723 and reach pre-fire DMC values larger than average, tend to induce high RBR. Then both bottom-up
724 fuel drying/dying and top-down early meteorological drying are strong drivers of fire severity.

725 Although these results provide an overview of the prediction of RBR, our study has several
726 limitations. First, we only use general-purpose vegetation indices that are only approximations of
727 fuel behaviour, which is particularly true for fire-weather codes. The latter variables only work

728 with coarse meteorological data, and do not take into account water storage capacities in the soil.
729 In addition, NDVI is only sensitive to the visible overstory greenness, whereas fire affects both
730 overstory and understory, and RBR is subject to capture impacts on both. Moreover, we do not use
731 a phenological correction in the RBR calculation, which could improve the transferability of the
732 burn severity assessment (Parks et al., 2018b) in the future and then strengthen our conclusions.
733 Finally, further research is needed to better characterize spatial aggregates at a finer spatial scale,
734 and including broader fuel and meteorological conditions would allow to improve the accuracy of
735 our predictions and the generalisability of our conclusions.

736 **Appendix A. Supplementary data**

737 Figures A.1, A.2 and A.3 and Tables A.1.

738 **References**

- 739 Acar-Denizli, N., Delicado, P., Basarir, G., Caballero, I., 2018. Functional regression on remote sensing data in
740 oceanography. *Environmental and Ecological Statistics* 25, 277–304. doi:10.1007/s10651-018-0405-7.
- 741 Allard, V., Ourcival, J.M., Rambal, S., Joffre, R., Rocheteau, A., 2008. Seasonal and annual variation of carbon
742 exchange in an evergreen mediterranean forest in southern france. *Global Change Biology* 14, 714–725. doi:10.
743 1111/j.1365-2486.2008.01539.x.
- 744 Andrews, P.L., 2018. The Rothermel surface fire spread model and associated developments: A comprehensive
745 explanation. doi:10.2737/rmrs-gtr-371.
- 746 Bachmann, A., Allgöwer, B., 2001. A consistent wildland fire risk terminology is needed! *Fire Management Today*
747 61, 28–33.
- 748 Baetens, L., Desjardins, C., Hagolle, O., 2019. Validation of copernicus sentinel-2 cloud masks obtained from maja,
749 sen2cor, and fmask processors using reference cloud masks generated with a supervised active learning procedure.
750 *Remote Sensing* 11. doi:10.3390/rs11040433.
- 751 Barbero, R., Abatzoglou, J.T., Pimont, F., Ruffault, J., Curt, T., 2020. Attributing increases in fire weather to anthro-
752 pogenic climate change over france. *Frontiers in Earth Science* 8. doi:10.3389/feart.2020.00104.
- 753 Barbero, R., Curt, T., Ganteaume, A., Maillé, E., Jappiot, M., Bellet, A., 2019. Simulating the effects of weather
754 and climate on large wildfires in france. *Natural Hazards and Earth System Sciences* 19, 441–454. doi:10.5194/
755 nhess-19-441-2019.

756 Birch, D.S., Morgan, P., Kolden, C.A., Abatzoglou, J.T., Dillon, G.K., Hudak, A.T., Smith, A.M.S., 2015. Vegetation,
757 topography and daily weather influenced burn severity in central idaho and western montana forests. *Ecosphere* 6,
758 art17. doi:10.1890/ES14-00213.1.

759 Bountouraby, B., Vega-Garcia, C., Vadillo, P.J., Ameztegui, A., Rodrigues, M., 2023. The relationship between fire
760 severity and burning efficiency for estimating wildfire emissions in mediterranean forests. *Journal of Forestry*
761 *Research* 34, 1–12. doi:10.1007/s11676-023-01599-1.

762 Bradshaw, L.S., Deeming, J.E., Burgan, R.E., Cohen, J.D., 1984. The 1978 National Fire-Danger Rating System:
763 technical documentation. doi:10.2737/int-gtr-169.

764 Breiman, L., 2001. Random forests. *Machine learning* 45, 5–32. doi:10.1023/A:1010933404324.

765 Brodrick, P.G., Asner, G.P., 2017. Remotely sensed predictors of conifer tree mortality during severe drought. *Envi-*
766 *ronmental Research Letters* 12, 115013. doi:10.1088/1748-9326/aa8f55.

767 Burgan, R.E., Klaver, R.W., Klaver, J.M., 1998. Fuel models and fire potential from satellite and surface observations.
768 *International journal of wildland fire* 8, 159–170. doi:10.1071/WF9980159.

769 Byram, G.M., 1959. Combustion of forest fuels. in ‘forest fire: control and use’.(ed. kp davis) pp. 61–89.

770 Cardot, H., Ferraty, F., Sarda, P., 1999. Functional linear model. *Statistics & Probability Letters* 45, 11–22. doi:10.
771 1016/S0167-7152(99)00036-X.

772 Castel-Clavera, J., Pimont, F., Opitz, T., Ruffault, J., Rivière, M., Dupuy, J.L., 2023. Disentangling the factors of
773 spatio-temporal patterns of wildfire activity in south-eastern france. *International Journal of Wildland Fire* 32,
774 15–28. doi:10.1071/WF22086.

775 Chéret, V., Denux, J.P., 2007. Mapping wildfire danger at regional scale with an index model integrating coarse
776 spatial resolution remote sensing data. *Journal of Geophysical Research: Biogeosciences* 112, 112. doi:10.1029/
777 2005JG000125.

778 Chéret, V., Denux, J.P., 2011. Analysis of modis ndvi time series to calculate indicators of mediterranean forest fire
779 susceptibility. *GIScience & Remote Sensing* 48, 171–194. doi:10.2747/1548-1603.48.2.171.

780 Chuvieco, E., Cocero, D., Riaño, D., Martin, P., Martinez-Vega, J., Riva, J., Perez-Cabello, F., 2004. Combining ndvi
781 and surface temperature for the estimation of live fuel moisture content in forest fire danger rating. *Remote Sensing*
782 *of Environment* 92, 322–331. doi:10.1016/j.rse.2004.01.019.

783 Chuvieco, E., Deshayes, M., Stach, N., Cocero, D., Riaño, D., 1999. Short-term fire risk: foliage moisture content
784 estimation from satellite data. pp. 17–38. doi:10.1007/978-3-642-60164-4_3.

785 Chuvieco, E., Riaño, D., Aguado, I., Cocero, D., 2002. Estimation of fuel moisture content from multitemporal
786 analysis of landsat thematic mapper reflectance data: Applications in fire danger assessment. *International Journal*
787 *of Remote Sensing* 23, 2145–2162. doi:10.1080/01431160110069818.

788 Chuvieco, E., Riaño, D., Danson, F.M., Martin, P., 2006. Use of a radiative transfer model to simulate the postfire
789 spectral response to burn severity. *Journal of Geophysical Research: Biogeosciences* 111, 15. doi:10.1029/

790 2005JG000143.

791 Costa-Saura, J.M., Bacciu, V., Ribotta, C., Spano, D., Massaiu, A., Sirca, C., 2022. Predicting and mapping potential
792 fire severity for risk analysis at regional level using google earth engine. *Remote Sensing* 14. doi:10.3390/
793 rs14194812.

794 Dillon, G.K., Holden, Z.A., Morgan, P., Crimmins, M.A., Heyerdahl, E.K., Luce, C.H., 2011. Both topography and
795 climate affected forest and woodland burn severity in two regions of the western us, 1984 to 2006. *Ecosphere* 2,
796 art130. doi:10.1890/ES11-00271.1.

797 Dupuy, J.I., Fargeon, H., Martin-StPaul, N., Pimont, F., Ruffault, J., Guijarro, M., Hernando, C., Madrigal, J., Fernan-
798 des, P., 2020. Climate change impact on future wildfire danger and activity in southern europe: a review. *Annals*
799 *of Forest Science* 77, 35. doi:10.1007/s13595-020-00933-5.

800 Escuin, S., Navarro Cerrillo, R., Fernández, P., 2008. Fire severity assessment by using nbr (normalised burn ratio)
801 and ndvi (normalised difference vegetation index) derived from landsat tm/etm images. *International Journal of*
802 *Remote Sensing* 29, 1053–1073. doi:10.1080/01431160701281072.

803 Estes, B.L., Knapp, E.E., Skinner, C.N., Miller, J.D., Preisler, H.K., 2017. Factors influencing fire severity under
804 moderate burning conditions in the klamath mountains, northern california, usa. *Ecosphere* 8, e01794. doi:10.
805 1002/ecs2.1794.

806 Fang, L., Yang, J., White, M., Liu, Z., 2018. Predicting potential fire severity using vegetation, topography and surface
807 moisture availability in a eurasian boreal forest landscape. *Forests* 9. doi:10.3390/f9030130.

808 Fang, L., Yang, J., Zu, J., Li, G., Zhang, J., 2015. Quantifying influences and relative importance of fire weather,
809 topography, and vegetation on fire size and fire severity in a chinese boreal forest landscape. *Forest Ecology and*
810 *Management* 356, 2–12. doi:10.1016/j.foreco.2015.01.011. special Section: The characteristics, impacts
811 and management of forest fire in China.

812 Fargeon, H., 2019. Impact of climate change on future wildfire danger and activity in France. Ph.D. thesis. Institut
813 agronomique, vétérinaire et forestier de France.

814 Fargeon, H., Pimont, F., Martin-Stpaul, N., De Cáceres, M., Ruffault, J., Barbero, R., Dupuy, J.L., 2020. Projections
815 of fire danger under climate change over france: where do the greatest uncertainties lie? *Climatic Change* 160,
816 479–493. doi:10.1007/s10584-019-02629-w.

817 Fassnacht, F.E., Schmidt-Riese, E., Kattenborn, T., Hernández, J., 2021. Explaining sentinel 2-based dnbr and rdnbr
818 variability with reference data from the bird’s eye (uas) perspective. *International Journal of Applied Earth Obser-*
819 *vation and Geoinformation* 95, 102262. doi:10.1016/j.jag.2020.102262.

820 Febrero-Bande, M., De La Fuente, M.O., 2012. Statistical computing in functional data analysis: The r package fda.
821 *Journal of statistical Software* 51, 1–28.

822 Fernández-García, V., Beltrán-Marcos, D., Fernández-Guisuraga, J.M., Marcos, E., Calvo, L., 2022. Predicting
823 potential wildfire severity across southern europe with global data sources. *Science of The Total Environment* 829,

824 154729. doi:10.1016/j.scitotenv.2022.154729.

825 Fernández-Guisuraga, J.M., Fernandes, P.M., Marcos, E., Beltrán-Marcos, D., Sarricolea, P., Farris, M., Calvo, L.,
826 2023. Caution is needed across mediterranean ecosystems when interpreting wall-to-wall fire severity estimates
827 based on spectral indices. *Forest Ecology and Management* 546, 121383. doi:10.1016/j.foreco.2023.121383.

828 Field, R.D., Spessa, A.C., Aziz, N.A., Camia, A., Cantin, A., Carr, R., de Groot, W.J., Dowdy, A.J., Flannigan,
829 M.D., Manomaiphiboon, K., Pappenberger, F., Tanpipat, V., Wang, X., 2015. Development of a global fire weather
830 database. *Natural Hazards and Earth System Sciences* 15, 1407–1423. doi:10.5194/nhess-15-1407-2015.

831 Fox, D., Carrega, P., Ren, Y., Caillouet, P., Bouillon, C., Robert, S., 2018. How wildfire risk is related to urban
832 planning and fire weather index in se france (1990–2013). *Science of The Total Environment* 621, 120–129.
833 doi:https://doi.org/10.1016/j.scitotenv.2017.11.174.

834 Frescino, T.S., Edwards Jr., T.C., Moisen, G.G., 2001. Modeling spatially explicit forest structural attributes us-
835 ing generalized additive models. *Journal of Vegetation Science* 12, 15–26. doi:10.1111/j.1654-1103.2001.
836 tb02613.x.

837 Galizia, L.F., Curt, T., Barbero, R., Rodrigues, M., 2021. Assessing the accuracy of remotely sensed fire datasets
838 across the southwestern mediterranean basin. *Natural Hazards and Earth System Sciences* 21, 73–86. doi:10.
839 5194/nhess-21-73-2021.

840 Ganteaume, A., Barbero, R., 2019. Contrasting large fire activity in the french mediterranean. *Natural Hazards and*
841 *Earth System Sciences* 19, 1055–1066. doi:10.5194/nhess-19-1055-2019.

842 García, M., Riaño, D., Yebra, M., Salas, J., Cardil, A., Monedero, S., Ramirez, J., Martín, M.P., Vilar, L., Gajardo,
843 J., Ustin, S., 2020. A live fuel moisture content product from landsat tm satellite time series for implementation in
844 fire behavior models. *Remote Sensing* 12. doi:10.3390/rs12111714.

845 Goldsmith, J., Scheipl, F., 2014. Estimator selection and combination in scalar-on-function regression. *Computational*
846 *Statistics & Data Analysis* 70, 362–372. doi:10.1016/j.csda.2013.10.009.

847 González, M.E., Gómez-González, S., Lara, A., Garraud, R., Díaz-Hormazábal, I., 2018. The 2010–2015
848 megadrought and its influence on the fire regime in central and south-central chile. *Ecosphere* 9, e02300.
849 doi:10.1002/ecs2.2300.

850 González-Alonso, F., de Miguel, S.M., Roldán-Zamarrón, A., García-Gigorro, S., Gozalo, J.M.C., 2006. Forest
851 biomass estimation through ndvi composites. the role of remotely sensed data to assess spanish forests as carbon
852 sinks. *International Journal of Remote Sensing* 27, 5409–5415. doi:10.1080/01431160600830748.

853 de Groot, W.J., 1987. Interpreting the canadian forest fire weather index (fwi) system, in: *Fourth Central Regional*
854 *Fire Weather Committee Scientific and Technical Seminar.*, pp. 3–14.

855 Guisan, A., Edwards, T.C., Hastie, T., 2002. Generalized linear and generalized additive models in studies of species
856 distributions: setting the scene. *Ecological Modelling* 157, 89–100. doi:10.1016/S0304-3800(02)00204-1.

857 Hagolle, O., Dedieu, G., Mougenot, B., Debaecker, V., Duchemin, B., Meygret, A., 2008. Correction of aerosol effects

858 on multi-temporal images acquired with constant viewing angles: Application to formosat-2 images. *Remote*
859 *Sensing of Environment* 112, 1689–1701. doi:10.1016/j.rse.2007.08.016. *remote Sensing Data Assimilation*
860 *Special Issue*.

861 Hagolle, O., Huc, M., Pascual, D., Dedieu, G., 2010. A multi-temporal method for cloud detection, applied to
862 formosat-2, ven μ s, landsat and sentinel-2 images. *Remote Sensing of Environment* 114, 1747–1755. doi:10.
863 1016/j.rse.2010.03.002.

864 Hagolle, O., Huc, M., Villa Pascual, D., Dedieu, G., 2015. A multi-temporal and multi-spectral method to estimate
865 aerosol optical thickness over land, for the atmospheric correction of formosat-2, landsat, ven μ s and sentinel-2
866 images. *Remote Sensing* 7, 2668–2691. doi:10.3390/rs70302668.

867 Hernandez, C., Drobinski, P., Turquety, S., 2015a. How much does weather control fire size and intensity in the
868 mediterranean region? *Annales Geophysicae* 33, 931–939. doi:10.5194/angeo-33-931-2015.

869 Hernandez, C., Keribin, C., Drobinski, P., Turquety, S., 2015b. Statistical modelling of wildfire size and intensity:
870 a step toward meteorological forecasting of summer extreme fire risk. *Annales Geophysicae* 33, 1495–1506.
871 doi:10.5194/angeo-33-1495-2015.

872 Hoaglin, D.C., 2003. John w. tukey and data analysis. *Statistical Science* 18, 311–318.

873 Hoaglin, D.C., Iglewicz, B., 1987. Fine-tuning some resistant rules for outlier labeling. *Journal of the American*
874 *Statistical Association* 82, 1147–1149.

875 Hoaglin, D.C., Iglewicz, B., Tukey, J.W., 1986. Performance of some resistant rules for outlier labeling. *Journal of*
876 *the American Statistical Association* 81, 991–999. doi:10.1080/01621459.1986.10478363.

877 Holden, Z.A., Morgan, P., Evans, J.S., 2009. A predictive model of burn severity based on 20-year satellite-inferred
878 burn severity data in a large southwestern us wilderness area. *Forest Ecology and Management* 258, 2399–2406.
879 doi:10.1016/j.foreco.2009.08.017.

880 Holz, A., Kitzberger, T., Paritsis, J., Veblen, T.T., 2012. Ecological and climatic controls of modern wildfire activity
881 patterns across southwestern south america. *Ecosphere* 3, art103. doi:10.1890/ES12-00234.1.

882 Hudak, A., Morgan, P., Bobbitt, M., Smith, A., Lewis, S., Lentile, L., Robichaud, P., Clark, J., McKinley, R., 2007.
883 The relationship of multispectral satellite imagery to immediate fire effects. *Fire Ecology* 3, 64–90. doi:10.4996/
884 fireecology.0301064.

885 Hunsicker, M.E., Kappel, C.V., Selkoe, K.A., Halpern, B.S., Scarborough, C., Mease, L., Amrhein, A., 2016. Charac-
886 terizing driver–response relationships in marine pelagic ecosystems for improved ocean management. *Ecological*
887 *Applications* 26, 651–663. doi:10.1890/14-2200.

888 Irish, R.R., 2000. Landsat 7 automatic cloud cover assessment, in: Shen, S.S., Descour, M.R. (Eds.), *Algorithms for*
889 *Multispectral, Hyperspectral, and Ultraspectral Imagery VI*, International Society for Optics and Photonics. SPIE.
890 pp. 348 – 355. doi:10.1117/12.410358.

891 Jain, T.B., Graham, R.T., 2007. The relation between tree burn severity and forest structure in the rocky mountains,

892 in: Restoring fire-adapted ecosystems: Proceedings of the 2005 national silviculture workshop. Tahoe City, CA.
893 Albany, CA. USDA Forest Service. Pacific Southwest Research Station, pp. 213–250.

894 Kaneko, H., 2022. Cross-validated permutation feature importance considering correlation between features. *Analyt-*
895 *ical Science Advances* 3, 278–287. doi:10.1002/ansa.202200018.

896 Kang, Z., Quan, X., Lai, G., 2023. Assessing the effects of fuel moisture content on the 2018 megafires in california.
897 *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 16, 868–877. doi:10.1109/
898 *JSTARS*.2022.3232665.

899 Keeley, J., 2009. Fire intensity, fire severity and burn severity: A brief review and suggested usage. *International*
900 *Journal of Wildland Fire* 18, 116–126. doi:10.1071/WF07049.

901 Key, C., Benson, N., 2005. Landscape Assessment (LA) Sampling and Analysis Methods. pp. LA 1–51.

902 Kokaly, R.F., Rockwell, B.W., Haire, S.L., King, T.V., 2007. Characterization of post-fire surface cover, soils, and
903 burn severity at the cerro grande fire, new mexico, using hyperspectral and multispectral remote sensing. *Remote*
904 *Sensing of Environment* 106, 305–325. doi:10.1016/j.rse.2006.08.006.

905 Kokoszka, P., Reimherr, M., 2017. Introduction to functional data analysis. CRC press.

906 Lecina-Díaz, J., Alvarez, A., Retana, J., 2014. Extreme fire severity patterns in topographic, convective and wind-
907 driven historical wildfires of mediterranean pine forests. *PloS one* 9, e85127. doi:10.1371/journal.pone.
908 0085127.

909 Lewis, S.A., Robichaud, P.R., Hudak, A.T., Strand, E.K., Eitel, J.U.H., Brown, R.E., 2021. Evaluating the persistence
910 of post-wildfire ash: A multi-platform spatiotemporal analysis. *Fire* 4. doi:10.3390/fire4040068.

911 Li, Y., Robinson, S.V., Nguyen, L.H., Liu, J., 2023. Satellite prediction of coastal hypoxia in the northern gulf of
912 mexico. *Remote Sensing of Environment* 284, 113346. doi:10.1016/j.rse.2022.113346.

913 Limousin, J.M., Rambal, S., Ourcival, J.M., Rodríguez-Calcerrada, J., Pérez-Ramos, I.M., Rodríguez-Cortina, R.,
914 Misson, L., Joffre, R., 2012. Morphological and phenological shoot plasticity in a mediterranean evergreen oak
915 facing long-term increased drought. *Oecologia* 169, 565–577. doi:10.1007/s00442-011-2221-8.

916 Littell, J.S., Peterson, D.L., Riley, K.L., Liu, Y., Luce, C.H., 2016. A review of the relationships between drought and
917 forest fire in the united states. *Global Change Biology* 22, 2353–2369. doi:10.1111/gcb.13275.

918 López García, M.J., Caselles, V., 1991. Mapping burns and natural reforestation using thematic mapper data. *Geocarto*
919 *International* 6, 31–37. doi:10.1080/10106049109354290.

920 Maffei, C., Menenti, M., 2019. Predicting forest fires burned area and rate of spread from pre-fire multispectral
921 satellite measurements. *ISPRS Journal of Photogrammetry and Remote Sensing* 158, 263–278. doi:10.1016/j.
922 *isprsjprs*.2019.10.013.

923 Marra, G., Wood, S.N., 2011. Practical variable selection for generalized additive models. *Computational Statistics*
924 *& Data Analysis* 55, 2372–2387. doi:10.1016/j.csda.2011.02.004.

925 Miller, C., Harvey, B., Kane, V., Moskal, L., Alvarado, E., 2023. Different approaches make comparing studies of

926 burn severity challenging: a review of methods used to link remotely sensed data with the composite burn index.
927 *International Journal of Wildland Fire* 32, 449–475. doi:10.1071/WF22050.

928 Miller, J., Thode, A., 2007. Quantifying burn severity in a heterogeneous landscape with a relative version of the delta
929 normalized burn ratio (rdnbr). *Remote Sensing of Environment* 109, 66–80. doi:10.1016/j.rse.2006.12.006.

930 Ohana-Levi, N., Munitz, S., Ben-Gal, A., Netzer, Y., 2020. Evaluation of within-season grapevine evapotranspiration
931 patterns and drivers using generalized additive models. *Agricultural Water Management* 228, 105808. doi:10.
932 1016/j.agwat.2019.105808.

933 Parks, S.A., Dillon, G.K., Miller, C., 2014a. A new metric for quantifying burn severity: The relativized burn ratio.
934 *Remote Sensing* 6, 1827–1844. doi:10.3390/rs6031827.

935 Parks, S.A., Holsinger, L.M., Koontz, M.J., Collins, L., Whitman, E., Parisien, M.A., Loehman, R.A., Barnes, J.L.,
936 Bourdon, J.F., Boucher, J., Boucher, Y., Caprio, A.C., Collingwood, A., Hall, R.J., Park, J., Saperstein, L.B.,
937 Smetanka, C., Smith, R.J., Soverel, N., 2019. Giving ecological meaning to satellite-derived fire severity metrics
938 across north american forests. *Remote Sensing* 11. doi:10.3390/rs11141735.

939 Parks, S.A., Holsinger, L.M., Panunto, M.H., Jolly, W.M., Dobrowski, S.Z., Dillon, G.K., 2018a. High-severity fire:
940 evaluating its key drivers and mapping its probability across western us forests. *Environmental Research Letters*
941 13, 044037. doi:10.1088/1748-9326/aab791.

942 Parks, S.A., Holsinger, L.M., Voss, M.A., Loehman, R.A., Robinson, N.P., 2018b. Correction: Parks et al. mean
943 composite fire severity metrics computed with google earth engine offer improved accuracy and expanded mapping
944 potential. *remote sens.* 2018, 10, 879. *Remote Sensing* 13. doi:10.3390/rs13224580.

945 Parks, S.A., Parisien, M.A., Miller, C., Dobrowski, S., 2014b. Fire activity and severity in the western us vary along
946 proxy gradients representing fuel amount and fuel moisture. *PloS one* 9, e99699. doi:10.1371/journal.pone.
947 0099699.

948 Pascolini-Campbell, M., Lee, C., Stavros, N., Fisher, J.B., 2022. Ecostress reveals pre-fire vegetation controls on
949 burn severity for southern california wildfires of 2020. *Global Ecology and Biogeography* 31, 1976–1989. doi:10.
950 1111/geb.13526.

951 Pellizzaro, G., Cesaraccio, C., Duce, P., Ventura, A., Zara, P., 2007. Relationships between seasonal patterns of live
952 fuel moisture and meteorological drought indices for mediterranean shrubland species. *International Journal of*
953 *Wildland Fire* 16, 232–241. doi:10.1071/WF06081.

954 Penot, V., Merlin, O., 2023. Estimating the water deficit index of a mediterranean holm oak forest from landsat opti-
955 cal/thermal data: A phenomenological correction for trees casting shadow effects. *IEEE Journal of Selected Topics*
956 *in Applied Earth Observations and Remote Sensing* 16, 5867–5880. doi:10.1109/JSTARS.2023.3288360.

957 Pesaresi, S., Mancini, A., Quattrini, G., Casavecchia, S., 2022. Functional analysis for habitat mapping in a special
958 area of conservation using sentinel-2 time-series data. *Remote Sensing* 14. doi:10.3390/rs14051179.

959 Pettorelli, N., Vik, J.O., Mysterud, A., Gaillard, J.M., Tucker, C., Stenseth, N.C., 2005. Using the satellite-derived

960 ndvi to assess ecological responses to environmental change. *Trends in ecology & evolution* 20, 503–10. doi:10.
961 1016/j.tree.2005.05.011.

962 Piedallu, C., Chéret, V., Denux, J., Perez, V., Azcona, J., Seynave, I., Gégout, J., 2019. Soil and climate differently
963 impact ndvi patterns according to the season and the stand type. *Science of The Total Environment* 651, 2874–2885.
964 doi:10.1016/j.scitotenv.2018.10.052.

965 Pimont, F., Fargeon, H., Opitz, T., Ruffault, J., Barbero, R., Martin-StPaul, N., Rigolot, E., RiviÉre, M., Dupuy, J.L.,
966 2021. Prediction of regional wildfire activity in the probabilistic bayesian framework of firelihood. *Ecological
967 Applications* 31, e02316. doi:10.1002/eap.2316.

968 Pimont, F., Ruffault, J., Opitz, T., Fargeon, H., Barbero, R., Castel Clavera, J., Martin-Stpaul, N., Rigolot, E., Dupuy,
969 J.L., 2022. Future expansion, seasonal lengthening and intensification of fire activity under climate change in
970 southeastern france. *International Journal of Wildland Fire* 32, 4–16. doi:10.1071/WF22103.

971 Ramsay, J., 2005. *Functional Data Analysis*. John Wiley & Sons, Ltd. p. 311. doi:10.1002/0470013192.bsa239.

972 Ramsay, J., Hooker, G., Graves, S., 2009. *Functional data analysis with R and MATLAB*. doi:10.1007/
973 978-0-387-98185-7.

974 Reed, B.C., Brown, J.F., VanderZee, D., Loveland, T.R., Merchant, J.W., Ohlen, D.O., 1994. Measuring phenological
975 variability from satellite imagery. *Journal of Vegetation Science* 5, 703–714. doi:10.2307/3235884.

976 Riley, K., Abatzoglou, J., Grenfell, I., Klene, A., Heinsch, F., 2013. The relationship of large fire occurrence with
977 drought and fire danger indices in the western usa, 1984–2008: The role of temporal scale. *International Journal
978 of Wildland Fire* 22. doi:10.1071/WF12149.

979 Rothermel, R.C., 1972. A mathematical model for predicting fire spread in wildland fuels. volume 115 of *USDA Forest
980 Service research paper INT*. Intermountain Forest & Range Experiment Station, Forest Service, U.S. Department
981 of Agriculture.

982 Ruffault, J., Curt, T., Martin-StPaul, N.K., Moron, V., Trigo, R.M., 2018a. Extreme wildfire events are linked to
983 global-change-type droughts in the northern mediterranean. *Natural Hazards and Earth System Sciences* 18, 847–
984 856. doi:10.5194/nhess-18-847-2018.

985 Ruffault, J., Limousin, J.M., Pimont, F., Dupuy, J.L., De Càceres, M., Cochard, H., Mouillot, F., Blackman, C.J.,
986 Torres-Ruiz, J.M., Parsons, R.A., Moreno, M., Delzon, S., Jansen, S., Oliosio, A., Choat, B., Martin-StPaul, N.,
987 2023. Plant hydraulic modelling of leaf and canopy fuel moisture content reveals increasing vulnerability of a
988 mediterranean forest to wildfires under extreme drought. *New Phytologist* 237, 1256–1269. doi:10.1111/nph.
989 18614.

990 Ruffault, J., Martin-StPaul, N., Pimont, F., Dupuy, J.L., 2018b. How well do meteorological drought indices predict
991 live fuel moisture content (lfmc)? an assessment for wildfire research and operations in mediterranean ecosystems.
992 *Agricultural and Forest Meteorology* 262, 391–401. doi:10.1016/j.agrformet.2018.07.031.

993 Ruffault, J., Mouillot, F., 2015. How a new fire-suppression policy can abruptly reshape the fire-weather relationship.

994 Ecosphere 6, art199. doi:10.1890/ES15-00182.1.

995 Salis, M., Arca, B., Alcasena, F., Arianoutsou, M., Bacciu, V., Duce, P., Duguay, B., Koutsias, N., Mallinis, G.,
996 Mitsopoulos, I., et al., 2016. Predicting wildfire spread and behaviour in mediterranean landscapes. *International*
997 *Journal of Wildland Fire* 25, 1015–1032. doi:10.1071/WF15081.

998 Salis, M., Del Giudice, L., Alcasena, F., Jahdi, R., Arca, B., Pellizzaro, G., Scarpa, C., Duce, P., 2023. Assessing cross-
999 boundary wildfire hazard, transmission, and exposure to communities in the italy-france maritime cooperation area.
1000 *Frontiers in Forests and Global Change* 6, 1–19. doi:10.3389/ffgc.2023.1241378.

1001 Schmidt, G., Jenkerson, C., Masek, J., Vermote, E., Gao, F., 2013. Landsat ecosystem disturbance adaptive processing
1002 system (ledaps) algorithm description. U.S. Geol. Surv. Open File Rep. 1057, 19. doi:10.3133/ofr20131057.

1003 Sebbar, B.e., Khabba, S., Merlin, O., Simonneaux, V., Hachimi, C.E., Kharrou, M.H., Chehbouni, A., 2023. Machine-
1004 learning-based downscaling of hourly era5-land air temperature over mountainous regions. *Atmosphere* 14.
1005 doi:10.3390/atmos14040610.

1006 Senf, C., Seidl, R., 2021. Persistent impacts of the 2018 drought on forest disturbance regimes in europe. *Biogeo-*
1007 *sciences* 18, 5223–5230. doi:10.5194/bg-18-5223-2021.

1008 Soverel, N.O., Perrakis, D.D., Coops, N.C., 2010. Estimating burn severity from landsat dnbr and rdnbr indices across
1009 western canada. *Remote Sensing of Environment* 114, 1896–1909. doi:10.1016/j.rse.2010.03.013.

1010 Tarrío, K., Tang, X., Masek, J.G., Claverie, M., Ju, J., Qiu, S., Zhu, Z., Woodcock, C.E., 2020. Comparison of cloud
1011 detection algorithms for sentinel-2 imagery. *Science of Remote Sensing* 2, 100010. doi:10.1016/j.srs.2020.
1012 100010.

1013 Taylor, A.H., Harris, L.B., Drury, S.A., 2021. Drivers of fire severity shift as landscapes transition to an active fire
1014 regime, klamath mountains, usa. *Ecosphere* 12, e03734. doi:10.1002/ecs2.3734.

1015 Van Wagner, C., et al., 1987. Development and structure of the Canadian forest fire weather index system. volume 35.

1016 Vega-Nieva, D.J., Briseño-Reyes, J., López-Serrano, P.M., Corral-Rivas, J.J., Pompa-García, M., Cruz-López, M.I.,
1017 Cuahutle, M., Ressler, R., Alvarado-Celestino, E., Burgan, R.E., 2024. Autoregressive forecasting of the number of
1018 forest fires using an accumulated modis-based fuel dryness index. *Forests* 15. doi:10.3390/f15010042.

1019 Vermote, E., Justice, C., Claverie, M., Franch, B., 2016. Preliminary analysis of the performance of the landsat 8/oli
1020 land surface reflectance product. *Remote Sensing of Environment* 185, 46–56. doi:10.1016/j.rse.2016.04.
1021 008. landsat 8 Science Results.

1022 Vidal, J.P., Martin, E., Franchistéguy, L., Baillon, M., Soubeyroux, J.M., 2010. A 50-year high-resolution atmospheric
1023 reanalysis over france with the safran system. *International Journal of Climatology* 30, 1627–1644. doi:10.1002/
1024 joc.2003.

1025 Viedma, O., Chico, F., Fernández, J., Madrigal, C., Safford, H., Moreno, J., 2020. Disentangling the role of prefire
1026 vegetation vs. burning conditions on fire severity in a large forest fire in se spain. *Remote Sensing of Environment*
1027 247, 111891. doi:10.1016/j.rse.2020.111891.

- 1028 Viedma, O., Quesada, J., Torres, I., Santis, A., Moreno, J., 2014. Fire severity in a large fire in a pinus pinaster
1029 forest is highly predictable from burning conditions, stand structure, and topography. *Ecosystems* 18, 237–250.
1030 doi:10.1007/s10021-014-9824-y.
- 1031 Viegas, D., J, P., MT, V., R, O., 2001. Estimating live fine fuel moisture content using meteorologically-based indices.
1032 *International Journal of Wildland Fire* 10, 223–240. doi:10.1071/WF01022.
- 1033 Wagenbrenner, N.S., Forthofer, J.M., Lamb, B.K., Shannon, K.S., Butler, B.W., 2016. Downscaling surface wind
1034 predictions from numerical weather prediction models in complex terrain with windninja. *Atmospheric Chemistry
1035 and Physics* 16, 5229–5241. doi:10.5194/acp-16-5229-2016.
- 1036 Wang, X., Oliver, J., Swystun, T., Hanes, C.C., Erni, S., Flannigan, M.D., 2023. Critical fire weather conditions during
1037 active fire spread days in canada. *Science of The Total Environment* 869, 161831. doi:10.1016/j.scitotenv.
1038 2023.161831.
- 1039 Wang, X., Wotton, B.M., Cantin, A., Parisien, M.A., Anderson, K., Moore, B., Flannigan, M.D., 2017. cffdrs:
1040 An r package for the canadian forest fire danger rating system. *Ecological Processes* 6, 5. doi:10.1186/
1041 s13717-017-0070-z.
- 1042 Wells, A.G., Hawbaker, T.J., Hiers, J.K., Kean, J., Loehman, R.A., Steblein, P.F., 2019. Predicting burn severity for
1043 integration with post-fire debris-flow hazard assessment: a case study from the upper colorado river basin, usa.
1044 *International Journal of Wildland Fire* 32, 1315–1331. doi:10.1071/WF22200.
- 1045 Williams, R., Gill, A., Moore, P., 1998. Seasonal changes in fire behaviour in a tropical savanna in northern australia.
1046 *International Journal of Wildland Fire* 8, 227–239. doi:10.1071/WF9980227.
- 1047 Wood, S.N., 2011. Fast stable restricted maximum likelihood and marginal likelihood estimation of semiparametric
1048 generalized linear models. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)* 73, 3–36.
1049 doi:10.1111/j.1467-9868.2010.00749.x.
- 1050 Yaro, A.S., Maly, F., Prazak, P., 2023. Outlier detection in time-series receive signal strength observation using z-score
1051 method with sn scale estimator for indoor localization. *Applied Sciences* 13. doi:10.3390/app13063900.
- 1052 Yebra, M., Chuvieco, E., Riaño, D., 2008. Estimation of live fuel moisture content from modis images for fire risk
1053 assessment. *Agricultural and Forest Meteorology* 148, 523–536. doi:10.1016/j.agrformet.2007.12.005.
- 1054 Yebra, M., Dennison, P.E., Chuvieco, E., Riaño, D., Zylstra, P., Hunt, E.R., Danson, F.M., Qi, Y., Jurdao, S., 2013.
1055 A global review of remote sensing of live fuel moisture content for fire danger assessment: Moving towards
1056 operational products. *Remote Sensing of Environment* 136, 455–468. doi:10.1016/j.rse.2013.05.029.
- 1057 Zhang, X., Friedl, M.A., Schaaf, C.B., Strahler, A.H., Hodges, J.C., Gao, F., Reed, B.C., Huete, A., 2003.
1058 Monitoring vegetation phenology using modis. *Remote Sensing of Environment* 84, 471–475. doi:10.1016/
1059 S0034-4257(02)00135-9.
- 1060 Zhu, X., Liu, D., 2015. Improving forest aboveground biomass estimation using seasonal landsat ndvi time-series.
1061 *ISPRS Journal of Photogrammetry and Remote Sensing* 102, 222–231. doi:10.1016/j.isprsjprs.2014.08.

1062 014.

1063 Zhu, Z., Qiu, S., He, B., Deng, C., 2018. Cloud and cloud shadow detection for Landsat images: The fundamental
1064 basis for analyzing Landsat time series. p. 21. doi:10.1201/9781315166636-1.

1065 Zuur, A., Ieno, E.N., Walker, N., Saveliev, A.A., Smith, G.M., 2009. Mixed Effects Models and Extensions in
1066 Ecology with R. Springer, New York, USA.

Chapitre 4

Comparaison et analyse des performances de prédiction de quatre indices satellitaires de sévérité des incendies

4.1 Introduction

Dans l'objectif d'effectuer une cartographie de la sévérité potentielle, prédire les quatre FSI de référence ($dNBR$, RBR , $RdNBR$, NBR_{post}) assure une prédiction robuste. Une classification par niveau de sévérité de terrain peut être réalisée a posteriori de la prédiction des FSI , en utilisant des classes de FSI déjà connues pour une large gamme de milieux (Costa-Saura et al., 2022; Epting et al., 2005; Escuin et al., 2008; Parks et al., 2018a,b; Taylor et al., 2021). Cette approche est d'autant plus importante qu'aucun de ces indices ne fait consensus quant à sa capacité à estimer au mieux la sévérité de terrain (Epting et al., 2005; Escuin et al., 2008; Hudak et al., 2007b). Cependant, de par leur formulation mathématique, ces quatre indices dépendent différemment des conditions pré-feu (NBR_{pre}) et des conditions post-feu (NBR_{post}). A priori, cela pourrait avoir une influence sur les performances de prédictions. À ce jour, aucune étude n'a étudié les différences de performances de prédiction entre ces FSI . Les Sections 4.2 et 4.3 présentent la réalisation et les résultats de cette comparaison sur la base d'un article disponible en Section 4.5 qui fournit l'ensemble des détails. Enfin une conclusion générale sur la prédiction des FSI et de la sévérité clôture ce Chapitre (Section 4.4).

4.2 Matériel et méthodes

L'aire d'étude est identique à celle du Chapitre précédent (voir Section 3.2.1). Les prédicteurs utilisés sont ceux sélectionnés par le modèle FLM au chapitre précédent ($NDVI$, DMC , DC , DOY), sauf le FWI qui se substitue à l' ISI et l'absence de la latitude. Le modèle utilisé le permettant (BRT), les classes d'occupation du sol sont intégrées comme prédicteur. L'échelle spatiale de travail reste l'agrégat spatial Feu-OS. Le modèle utilise les données mesurées ou estimées juste avant l'incendie. Quatre FSI sont prédits : le $dNBR$, le RBR , le $RdNBR$ et le NBR_{post} . Le NBR_{post} est le seul indice mono-temporel dont la formulation ne dépend pas des conditions pré-feu (voir expressions mathématiques (2.1),

Indice	Prédiction Basée sur le FSI R	Prédiction Basée sur le NBR_{post} R
dNBR	0.74	0.78
RBR	0.58	0.59
RdNBR	0.35	0.43
NBR_{post}	0.48	
NBR_{pre}	0.93	
RBR_{pre}	0.93	
$RdNBR_{pre}$	0.93	

TABLE 4.1 – Performances de prédiction (R) de la prédiction Basée sur le FSI des FSI/FSI_{pre} par rapport aux FSI/FSI_{pre} déduits des mesures, et de la prédiction Basée sur le NBR_{post} des FSI dérivés des NBR_{post} prédits et des NBR_{pre} déduits des mesures, par rapport aux FSI déduits des mesures.

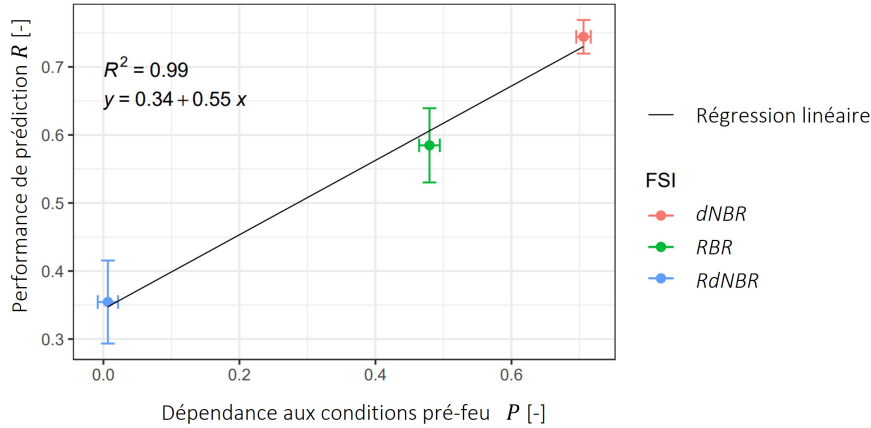


FIGURE 4.1 – Nuages de points de la performance de prédiction (R) (prédiction Basée sur le FSI) par rapport à la dépendance des FSI aux conditions avant l'incendie (P) (corrélation entre le FSI_{pre} prédit et le FSI). La longueur des barres d'erreur est l'écart type de P (horizontal) et de R (vertical), et les coordonnées des points sont les moyennes de P et de R .

(2.2),(2.3),(2.4).

Deux stratégies de prédictions sont envisagées. La prédiction dite "Basée sur le FSI " prédit directement chaque FSI , alors que la prédiction "Basée sur le NBR_{post} " déduit chaque FSI du NBR_{post} prédit et du NBR_{pre} dérivé des mesures satellitaires. Les composantes pré-feu (FSI_{pre}) de chacun des FSI sont aussi prédites (NBR_{pre} , RBR_{pre} et $RdNBR_{pre}$). Toutes les méthodes de prédiction sont identiques à celle du Chapitre 3 (Voir Section 3.2.3).

4.3 Résultats et discussion

Le Tableau 4.1 présente les performances de prédiction pour les quatre FSI , les FSI_{pre} (composante pré-feu du FSI) et pour les deux stratégies de prédiction (Basée sur le FSI et Basée sur le NBR_{post}). Quel que soit le FSI bi-temporel, les FSI_{pre} sont bien prédits. En effet, le NBR_{pre} est très corrélé au $NDVI$ ($R=0.94$) et le modèle utilisé (BRT) modélise bien les non-linéarités. Par ailleurs, les performances de prédiction de la stratégie Basée sur le FSI dépendent fortement des FSI : le $dNBR$ est le mieux prédit, suivi par le RBR , le NBR_{post} et le $RdNBR$.

L'étude de la dépendance des R aux conditions pré-feu éclaire les différences de R entre les FSI bi-temporels. La figure 4.1 représente R en fonction de la dépendance du FSI au FSI_{pre} prédit : plus la performance de prédiction est élevée, plus le FSI est dépendant (ie corrélé) au FSI_{pre} prédit. Cela implique que les bonnes performances de prédiction des FSI bi-temporels sont dues à la bonne prédiction des FSI_{pre} .

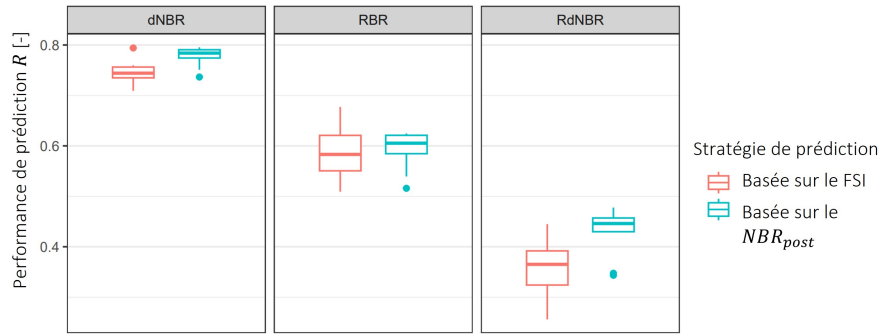


FIGURE 4.2 – Boîtes à moustaches des performances de prédiction (R) par FSI et par méthode de prédiction.

La stratégie de prédiction Basée sur le NBR_{post} confirme ces résultats et elle améliore les performances de prédiction des FSI . La figure 4.2 présente les boîtes à moustaches des R en fonction de la stratégie de prédiction pour chacun des FSI bi-temporels. Les performances de prédiction pour la stratégie Basée sur le NBR_{post} sont au moins égales (RBR) voire supérieures ($dNBR$, $RdNBR$) à la stratégie Basée sur le FSI . Il est probable que la prédiction des FSI_{pre} , bien que très correcte, engendre une erreur supplémentaire dans la stratégie Basée sur le FSI par rapport à la stratégie Basée sur le NBR_{post} . Par ailleurs, ces résultats renforcent le fait que des performances de prédiction très différentes peuvent être atteintes avec des expressions mathématiques impliquant des dépendances aux conditions pré-feu différentes, même si l'origine de l'erreur de prédiction est commune (NBR_{post}).

4.4 Conclusion

Les performances de prédiction des FSI dépendent de la dépendance des FSI aux conditions pré-feu, connue a priori et bien prédites sinon. Ainsi les performances de prédiction comparées entre FSI peuvent être trompeuses. L'utilisation du NBR_{pre} déduit des mesures satellitaires (connu a priori d'un incendie) et du NBR_{post} prédit, dont la formulation ne dépend pas des conditions pré-feu, améliore la performance de prédiction des FSI bi-temporels. Par ailleurs, prédire le NBR_{post} permet de se concentrer uniquement sur les conditions inconnues avant la survenue d'un incendie. Nous conseillons donc que les efforts se portent sur la prédiction du NBR_{post} . Pour l'instant, les performances de prédiction du NBR_{post} sont insuffisantes et plusieurs pistes d'amélioration des modèles sont envisageables.

Tout d'abord, des approches mixtes statistiques/apprentissage machine peuvent être envisagées. En effet, les performances de prédiction du NBR_{post} pour l'approche FLM ($R = 0.46$, voir Chapitre 3) sont proches de celles obtenues dans ce Chapitre ($R = 0.48$). Bien que le modèle de ce Chapitre (modèle d'apprentissage machine) n'utilise que des variables statiques pré-feu, il est aussi plus complexe car il autorise l'utilisation de prédicteurs qualitatifs (classes d'occupation du sol) et modélise les interactions entre prédicteurs. Le modèle FLM reste un modèle statistique additif qui ne prend pas en compte les interactions entre variables, ni n'autorise l'intégration de variables qualitatives. Une approche mixte, combinant analyse de données fonctionnelles et apprentissage machine, est à envisager.

La détermination de proxys des dynamiques hydriques du combustible vivant à haute résolution spatiale et sensibles aux conditions de surface est à rechercher (Pascolini-Campbell et al., 2022). En effet, si le $NDVI$ et plus généralement le domaine optique (courte et moyenne longueurs d'onde) peut être utilisé comme un proxy du $LFMC$ (Chuvieco et al., 1999; García et al., 2020; Yebra et al., 2013), l'analyse menée au Chapitre 3 suggère plutôt que ses variations sont à associer aux variations de la quantité

de combustible sénescent/mort par rapport au combustible vivant (Burgan et al., 1998; Newnham et al., 2011). Les indices météorologiques utilisés dans les Chapitres 3 et 4, comme le *DMC* ou le *DC*, traduisent le forçage météorologique sur le combustible et peuvent être corrélés à la *LFMC* (Pellizzaro et al., 2007). Pourtant, ils ne prennent pas en compte les états de surface, notamment les spécificités des différentes stations forestières (espèces, sols). Par ailleurs, leur résolution spatiale importante (1-10 km) est plus large que l'échelle spatiale de variation de l'occupation du sol. Un proxy des dynamiques hydriques (dont le *LFMC* et le stress hydrique) du combustible à haute résolution spatiale, à la fois sensible aux états de surface et sensible au forçage météorologique peut être fourni par la télédétection optique/thermique. Outre la prédiction de la sévérité, ce proxy de l'état hydrique aurait une portée plus large au sein de la communauté étudiant les feux de forêt. En particulier, les approches physiques modélisant la propagation des fronts de flamme pourrait l'utiliser comme variable d'entrée de leur modèle (Andrews, 1986; Costes, 2021).

4.5 Article associé : "Prediction of potential fire severity : which remotely sensed optical fire severity index should we use ?"

Remote Sensing Applications: Society and Environment

Prediction of potential fire severity: which remotely sensed optical fire severity index should we use?

--Manuscript Draft--

Manuscript Number:	
Article Type:	Research Paper
Keywords:	Fire severity index; Normalized burn ratio; Forecasting performance; Potential severity; Modelling
Corresponding Author:	Victor PENOT Center for the Study of the Biosphere from Space FRANCE
First Author:	Victor PENOT
Order of Authors:	Victor PENOT François PIMONT Thomas OPITZ Olivier MERLIN
Abstract:	<p>To assess the future degree of environmental change caused by a the occurrence of a fire, i.e., potential fire severity, it is essential to predict it in areas not yet affected by fire. Potential fire severity can be forecasted (i.e., predicted at short temporal scales from days to weeks) using remotely sensed fire severity indices (FSI) such as the Normalized Burn Ratio (NBR), either through its difference composite before ([EQUATION]) and after ([EQUATION]) the fire, or solely with its post-fire value. The forecasting performance of an FSI is defined as the correlation (R) between predicted and observed FSI when predictions are made on fires that are not used for training. However, the formulas describing the mathematical dependence of different FSI on post- and pre-fire reflectance vary, which could affect their forecasting performance. This variability in forecasting performance remains poorly studied and understood. In this study, the forecasting performance of four common FSI is compared and assessed using data from the French Mediterranean region, well-recognized pre-fire predictors of fire severity, 79 summer fires, and a state-of-the-art machine-learning based modelling approach. The forecasting performance of FSI varies significantly, with R values ranging from 0.35 to 0.74. The ranking of FSI is shown to be strongly influenced by their dependence on pre-fire conditions, indicating that the choice of an FSI for prediction should not rely solely on its potentially misleading forecasting performance. Additionally, we found that the FSI derived by combining predicted [[EQUATION]] and satellite-measured [[EQUATION]] exhibit generally better forecasting performance than the directly predicted FSI. Therefore, the prediction of potential FSI should be based on predicted [[EQUATION]] and satellite-measured [[EQUATION]].</p>

1
2
3 **Highlights**
4

5
6 **2 Prediction of potential fire severity: which remotely sensed optical fire severity index should**
7
8 **3 we use?**
9

10
11 4 Victor Penot, François Pimont, Thomas Opitz, Olivier Merlin
12

- 13
14 5 • Forecasting performance depends on the FSI
15
16 6 • Dependence to pre-fire conditions largely explains FSI forecasting performance differences
17
18
19 7 • Predicted NBR_{post} and measured NBR_{pre} should be used for FSI predictions
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

Prediction of potential fire severity: which remotely sensed optical fire severity index should we use?

Victor Penot^a, François Pimont^c, Thomas Opitz^b, Olivier Merlin^a

^aUniversite de Toulouse, CNES/CNRS/IRD/INRAe, CESBio, 18 avenue Edouard Belin, Toulouse, 31401, France

^bBioSP, INRAE., Avignon, France

^cURFM, INRAE, Avignon, France

Abstract

To assess the future degree of environmental change caused by a the occurrence of a fire, i.e., potential fire severity, it is essential to predict it in areas not yet affected by fire. Potential fire severity can be forecasted (i.e., predicted at short temporal scales from days to weeks) using remotely sensed fire severity indices (FSI) such as the Normalized Burn Ratio (NBR), either through its difference composite before (NBR_{pre}) and after (NBR_{post}) the fire, or solely with its post-fire value. The forecasting performance of an FSI is defined as the correlation (R) between predicted and observed FSI when predictions are made on fires that are not used for training. However, the formulas describing the mathematical dependence of different FSI on post- and pre-fire reflectance vary, which could affect their forecasting performance. This variability in forecasting performance remains poorly studied and understood. In this study, the forecasting performance of four common FSI is compared and assessed using data from the French Mediterranean region, well-recognized pre-fire predictors of fire severity, 79 summer fires, and a state-of-the-art machine-learning based modelling approach. The forecasting performance of FSI varies significantly, with R values ranging from 0.35 to 0.74. The ranking of FSI is shown to be strongly influenced by their dependence on pre-fire conditions, indicating that the choice of an FSI for prediction should not rely solely on its potentially misleading forecasting performance. Additionally, we found that the FSI derived by combining predicted NBR_{post} and satellite-measured NBR_{pre} exhibit generally better forecasting performance than the directly predicted FSI. Therefore, the prediction of potential FSI should be based on predicted NBR_{post} and satellite-measured NBR_{pre} .

Keywords: Fire severity index, Normalized burn ratio, Forecasting performance, Potential

33 **1. Introduction**

34 Fire severity is defined as the fire effects on the local environment (Lentile et al., 2006). Fire
35 severity, can be quantified on the ground, with loss of organic matter, crown volume scorch, tree
36 mortality or post-fire twig diameter (Jain and Graham, 2007; Keeley, 2009; Miller et al., 2023), and
37 it has no universal unit of measurement. Given the ecological and fire impacts associated with fire
38 severity (e.g., carbon emissions (Veraverbeke et al., 2015), post-fire debris flow (Wells et al., 2019),
39 water quality (Shakesby et al., 2003), post-fire soil erosion (Marion et al., 1991)), predicting future
40 fire severity, i.e. potential fire severity, becomes crucial. Indeed, accurate predictions can help
41 assess the near-future sensitivity of ecosystems to fire and evaluate the effectiveness of mitigation
42 policies, such as fuel treatments (Parks et al., 2018a; Price and Bradstock, 2012; Stephens et al.,
43 2009). In the Mediterranean area, due to the lack of sufficient ground measurements of fire severity,
44 it is not possible to build robust statistical or machine learning models to predict potential ground
45 fire severity. Hence, it is necessary to find alternative proxies of fire severity, whose availability
46 and heterogeneity suit the requirements of statistical or machine learning modelling.

47 Optical data have proven their ability to derive fire severity indices (FSI), particularly the
48 Normalized Burnt Ratio (NBR) (López García and Caselles, 1991), which correlates well with
49 ground-based severity when assessed after the fire (García-Llamas et al., 2019; Parks et al., 2019).
50 Difference FSI, such as the Difference Normalized Burn Ratio (dNBR) (Key and Benson, 2005),
51 the Relativised dNBR (RdNBR) (Miller and Thode, 2007) or the Relative Burn Ratio (RBR) (Parks
52 et al., 2014), were built to better relate spectral information to ground-based measures of sever-
53 ity through regressions or other statistical modelling techniques, based on the relative or absolute
54 change in NBR between pre-fire (NBR_{pre}) and post-fire (NBR_{post}) dates.

55 The availability of remotely sensed FSI images over extended areas allows studying a wide
56 range of pre-fire conditions and a wide range of fire severity levels. It has opened up a field of
57 research to predict potential FSI (Fernández-García et al., 2022; Parks et al., 2018a; Taylor et al.,

58 *Email address:* victor.penot@iut-tlse3.fr (Victor Penot)

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

1
2
3
4 58 2021; Wells et al., 2019), using statistical or machine learning models. This approach makes it
5
6 59 possible to build a model using a training data set and then evaluate its forecasting performance
7
8 60 on a test data set that does not include the same fires as the training data set. For the moment,
9
10 61 all studies focus on predicting one FSI at a time. However, to build robust potential fire severity
11
12 62 maps, all four indices could be predicted together. Then, given the widely studied and experienced
13
14 63 FSI limits (Costa-Saura et al., 2022; Epting et al., 2005; Escuin et al., 2008; Parks et al., 2018a,b;
15
16 64 Taylor et al., 2021) they can be classified into ground fire severity levels, and the fire severity class
17
18 65 reached most often (for instance) can be chosen (ensemble modelling).

19 66 Before producing ensemble modelling derived maps of fire severity, it is important to study
20
21 67 the FSI respective forecasting performances. Among the studies that have predicted potential FSI
22
23 68 (Fernández-García et al., 2022; Parks et al., 2018a; Taylor et al., 2021), very few have investigated
24
25 69 the difference of forecasting performances between the various existing FSI. The forecasting per-
26
27 70 formance of an FSI is generally defined as the correlation (R) between the satellite-derived and
28
29 71 predicted FSI, when the prediction is made at a location (a fire) and time (test dataset) which are
30
31 72 not included in the training dataset. Gale and Cary (2022) built FSI models to explain the spatial
32
33 73 variability of dNBR, RdNBR and RBR within a single fire. They found that the explanatory fac-
34
35 74 tors of FSI change depending on the choice of FSI formulation. They suggested that for the FSI
36
37 75 that are highly correlated with NBR_{pre} (e.g. dNBR), these explanatory factors may explain the
38
39 76 NBR_{pre} . Viedma et al. (2020) predicted dNBR, RdNBR and RBR for a single fire and obtained
40
41 77 similar forecasting performances for all three FSI. However, both studies relied on training and
42
43 78 validation datasets from a single fire, which limits the scope of their conclusions. Thus, to the
44
45 79 authors' knowledge, there has been no study on the forecasting performance of different FSI using
46
47 80 the same set of predictors and independent fires in time and space for training and testing.

48 81 In this context, this study intercompares the forecasting performance of dNBR, RdNBR, RBR,
49
50 82 and NBR_{post} given the same set of predictors and fully independent training and testing data sets,
51
52 83 with the aim to better understand the factors that explain their differences. In practice, this study
53
54 84 addresses two main objectives: 1) to quantitatively assess the difference in forecasting perfor-
55
56 85 mance of dNBR, RBR, RdNBR and NBR_{post} given a set of explanatory variables, 2) to explain the
57
58 86 observed difference in forecasting performance of the four FSI.

1
2
3
4 87 The paper is structured as follows. Section 2 describes the study area, the remote sensing
5 88 and meteorological data used, and presents the model trained and tested. Section 3 presents and
6
7 89 discusses the results. Finally, Section 4 provides a summary of this study and a recommendation
8
9 90 for future research on potential FSI prediction.

91 **2. Material and methods**

92 In this Section we first present the study area and the fire land cover dataset (Section 2.1).
93 Then, we describe the satellite data and the formulation of the four FSI (Section 2.2). Finally, we
94 present the FSI predictors (Section 2.3).

95 *2.1. Study area and fire-land cover dataset*

96 The fire dataset consists of 79 forest fires that occurred in the French Mediterranean area
97 between 2016 and 2021, during the summer season (June-September). Climate is characterized by
98 warm and dry summers and mild winters, except in the mountainous area, which combines both
99 Mediterranean and mountain influences (Barbero et al., 2019). Figure 1 shows the studied fire
100 locations within the French Mediterranean region. Elevation of areas affected by fires ranges from
101 5 m to 1,439 m, with an average of 285 m above sea level. The main fire period includes July (26
102 fires) and August (35 fires), while the beginning and end of the season witness the remaining fires
103 (6 fires in June, 12 fires in September).

104 The French National Forest Service (Office National des Forêts, ONF) provides the fire perime-
105 ters. To limit the influence of biases related to firefighting activities, the pixels falling in a 50 m
106 buffer within the fire perimeter have been removed. A 100m buffer along roads and built-up
107 areas is applied to remove pixels where important pre-fire mitigation measures (fuel clearance)
108 and fire-fighting actions could have been applied. This may have influenced the expected re-
109 lationship between predictors and FSI. The French National Forest Database BDForet V2 from
110 Institut Géographique National (IGN) provides the land cover (LC) perimeters and classification.
111 The seven LC classes are defined according to their structure (open, closed, shrubland) and their
112 dominant tree classes (coniferous, deciduous, mixed, shrubland). In our study, we consider as
113 a statistical individual each spatial intersection between a fire perimeter and a land cover patch

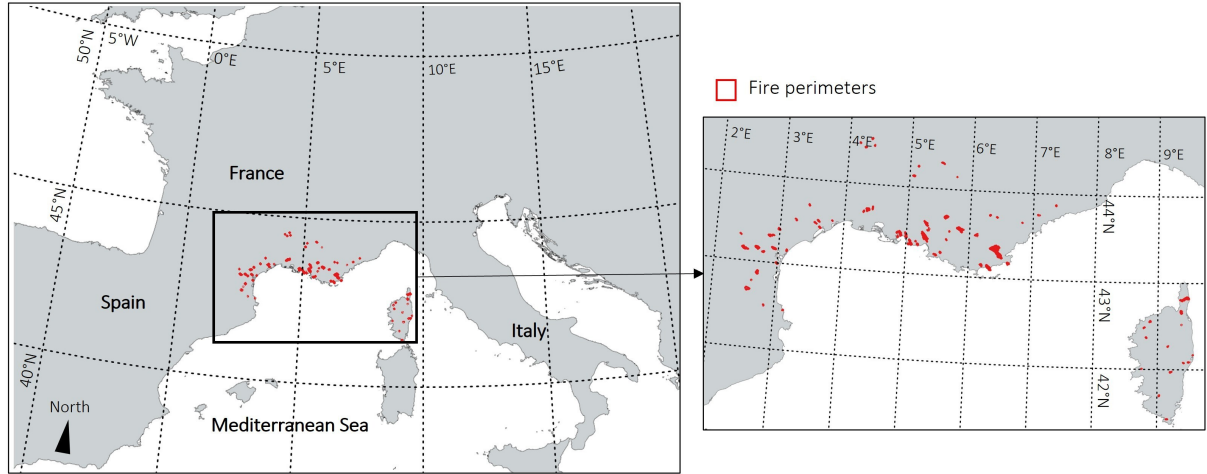


Figure 1: Map of the French Mediterranean area and the locations of the studied fires.

114 (fire-LC pairs). Using this approach we create fire-severity-related and fuel-consistent aggregates
 115 (Estes et al., 2017; Fang et al., 2018, 2015). We select fire-LC intersections of more than 13.5 ha,
 116 leading to 179 fire-LC pairs. Their final areas range from 14 ha to 1,238 ha.

117 2.2. Remotely sensed FSI

118 Sentinel-2 data are used to derive pre- and post-fire spectral indices. Sentinel-2A/2B satellites
 119 both provide reflectances with a 10-day revisit period, with a 5-day shift between Sentinel-2A
 120 and Sentinel-2B satellites. Data between 2016 and 2021 were downloaded from the Theia-Land
 121 repository with a level 2A-FRE processing, corrected for atmospheric and topographic effects
 122 thanks to the MAJA software (Baetens et al., 2019; Hagolle et al., 2008, 2010, 2015). For each
 123 fire, the FSI are computed from Sentinel-2 data collected immediately before and after the fire.
 124 The minimum frequency of clear pixels is set to 80% as we prioritise the overpass closest to
 125 fire ignition ([mean +/- standard deviation] 6.5 +/- 5.5 days before the fire) and end ([mean +/-
 126 standard deviation] 7.6 +/- 7.5 days after the fire) of each of the studied fires. The same pixel
 127 locations are used in the pre- and post-fire images to calculate the FSI from averaged near infrared
 128 (NIR – B8A band) and averaged short-wave infrared band 2 (SWIR2 – B12 band). Note that for
 129 every FSI, the corresponding FSI is the difference between pre-fire FSI (FSI_{pre}) and post-fire FSI

1
2
3
4 130 (FSI_{post}), with:

$$NBR = \frac{(NIR - SWIR2)}{(NIR + SWIR2)} \quad (1)$$

$$dNBR = NBR_{pre} - NBR_{post} \quad (2)$$

$$RdNBR = RdNBR_{pre} - RdNBR_{post} = \frac{NBR_{pre}}{\sqrt{|NBR_{pre}|}} - \frac{NBR_{post}}{\sqrt{|NBR_{pre}|}} \quad (3)$$

17 131 if $NBR_{pre} \leq 0.01$ then $NBR_{pre} = 0.01$

$$RBR = RBR_{pre} - RBR_{post} = \frac{NBR_{pre}}{1.001 + NBR_{pre}} - \frac{NBR_{post}}{1.001 + NBR_{pre}} \quad (4)$$

24 132 2.3. *FSI predictors*

25
26 133 The following sections describe the different variables used to predict FSI.

29 134 2.3.1. *Vegetation data*

30
31 135 We use two variables to characterise and quantify the vegetation properties. The normalized
32
33 136 difference vegetation index (NDVI), as a proxy for pre-fire live biomass (González-Alonso et al.,
34
35 137 2006; Zhu and Liu, 2015), shows good predictive ability for FSI (Parks et al., 2018a; Taylor et al.,
36
37 138 2021). It is calculated from averaged red (B4 band) and NIR ($NDVI = (NIR - red)/(NIR +$
38
39 139 $red)$ (5)) of the same pixels and over the same pre-fire satellite coverage as for FSI. Land cover
40
41 140 types, as defined in Section 2.1, are used as categorical variables to qualify the dominant tree and
42
43 141 shrub classes (Costa-Saura et al., 2022; Taylor et al., 2021; Viedma et al., 2020, 2014).

45 142 2.3.2. *Meteorological data and fire weather indices*

46
47 143 We use the SAFRAN reanalysis dataset (Vidal et al., 2010). Daily-averaged meteorological
48
49 144 data (air temperature, relative humidity, wind speed and 24-hour cumulated rain) are available
50
51 145 over an 8-km grid. Among the wide variety of fire-related meteorological indices, we choose
52
53 146 the codes provided by the Canadian Forest Fire Danger Rating System (CFFDRS) (Van Wagner
54
55 147 et al., 1987) since they show strong correlations with fire occurrence (Barbero et al., 2019; Pimont
56
57 148 et al., 2021), extension (Pimont et al., 2021) and severity (Birch et al., 2015; Fang et al., 2015).

1
2
3
4 149 We compute Duff Moisture Code (DMC) and Fire Weather Index (FWI) codes from the CFFDRS
5 150 system. Day-of-fire DMC and FWI depend on the relative humidity, the 24h-cumulative rain and
6
7 151 the air temperature. In addition, FWI takes into account the wind speed. We use the *cffdrs* R
8
9 152 package (Wang et al., 2017) and the daily mean data from the reanalysis dataset, except for the air
10
11 153 temperature, which is set to the maximum air temperature as in (Barbero et al., 2019).
12
13

14 154 2.3.3. *Topographic data and day of year*

15
16 155 The 25-m spatial resolution digital elevation model is provided by the French National Eleva-
17
18 156 tion Database (BDAlti) from IGN. The elevation is averaged for each fire-LC pair. The day of the
19
20 157 year is used to account for any temporal trend in gravity that may occur during the summer.
21
22

23 158 2.4. *Machine learning modelling*

24
25 159 Boosted Regression Trees (BRT) represent a state-of-the-art machine learning method widely
26
27 160 used in ecological and fire prediction due to its good predictive performance and identification
28
29 161 of relevant variables (Elith et al., 2008; Li et al., 2023; Viedma et al., 2020). We train and test
30
31 162 BRT with measured pre-fire remote sensing data, DMC and FWI, elevation, day of fire and LC
32
33 163 classes. BRT is fitted using a Gaussian distribution for the response variable with the R package
34
35 164 *gbm* (Ridgeway, 2006), and hyperparameter tuning is done with the R package *caret* (Kuhn, 2008).
36
37

38 165 2.5. *FSI forecasting performance*

39
40 166 To appropriately assess the forecasting performance of a model, the training and test datasets
41
42 167 should be independent in both time and space. This means that the fires and their corresponding
43
44 168 Fire-LC used to train the model should not be present in the test dataset. To achieve this, we
45
46 169 implemented a 10-fold cross-validation repeated 10 times. Consequently, each Fire (and its Fire-
47
48 170 LC) is predicted exactly 10 times as a test Fire (Fire-LC), ensuring it is not used for training. As a
49
50 171 consequence, 10 predictions of the whole dataset are done.

51 172 Following this methodology, the first approach, called "Difference-based", directly predicts
52
53 173 the FSI and the FSI_{pre} . We compute the correlation (R), which represents the forecasting perfor-
54
55 174 mance, and the Root Mean Square Error (RMSE) between the predicted and satellite-measured
56
57

1
2
3
4 175 FSI/ FSI_{pre} . Based on these 10 evaluations of R and RMSE, we calculate the mean and standard
5 176 deviation of R and RMSE.

7 177 In addition, we evaluate every FSI estimated using equations (1),(2),(3),(4), from the measured
8
9 178 NBR_{pre} and the predicted NBR_{post} . This prediction method is called “Post-based”. Each predicted
10
11 179 index is evaluated against the corresponding measured FSI using R and RMSE following the
12
13 180 same methodology as for the Difference-based prediction. These estimations based on measured
14
15 181 pre-fire conditions will allow us to disentangle the importance of pre-fire condition predictions in
16
17 182 the performance of FSI predictions.

20 183 **3. Results and discussion**

23 184 In Section 3.1, the forecasting performance of the four FSI (Difference-based predictions) and
24
25 185 their dependence to pre-fire conditions are first presented and discussed. Then, in Section 3.2 we
26
27 186 present and discuss the forecasting performance of the Post-based predictions.

30 187 *3.1. Forecasting performances of the four FSI and dependence to pre-fire conditions*

32 188 *3.1.1. Forecasting performances of the four FSI*

34 189 Table 1 presents the mean and standard deviation of forecasting performances (R) for the
35
36 190 Difference-based predictions. Whatever the formulation of FSI_{pre} , they show a good and almost
37
38 191 equal forecasting performance with a high correlation between predictions and observations (mean
39
40 192 $R=0.93$, see Table 1). In fact, all FSI_{pre} are defined in terms of NBR_{pre} only as a linear or non-
41
42 193 linear functions of NBR_{pre} . This relationship can be efficiently modelled by BRT with NDVI as
43
44 194 predictor given that the correlation between NDVI and measured NBR_{pre} is 0.94, and thanks to its
45
46 195 ability to account for nonlinearities.

47 196 The Difference-based forecasting performance strongly depends on the FSI: dNBR achieves
48
49 197 a relatively high R ($R=0.74$), followed by RBR ($R=0.58$), NBR_{post} ($R=0.48$) and finally RdNBR
50
51 198 ($R=0.35$), and the relatively small standard deviations of the R-values calculated through the cross-
52
53 199 validation scheme indicate that these differences are clearly significant. Our results show a strong
54
55 200 contrast of forecasting performances between the different FSI (see Table 1). We believe that
56
57 201 this study is the first to focus on the prediction of these four FSI using spatially and temporally

FSI	Difference-based prediction				Post-based prediction			
	Mean R	Standard deviation of R	Mean RMSE	Standard deviation of RMSE	Mean R	Standard deviation of R	Mean RMSE	Standard deviation of RMSE
dNBR	0.74	0.025	0.095	0.0041	0.78	0.019	0.090	0.0033
RBR	0.58	0.055	0.063	0.0036	0.59	0.037	0.064	0.0024
RdNBR	0.35	0.061	0.152	0.0056	0.43	0.047	0.146	0.0054
NBR_{post}	0.48	0.046	0.090	0.0033				
NBR_{pre}	0.93	0.005	0.044	0.0018				
RBR_{pre}	0.93	0.005	0.023	0.0009				
$RdNBR_{pre}$	0.93	0.005	0.037	0.0013				

Table 1: Prediction accuracies (R) and RMSE of Difference-based prediction of FSI, or FSI_{pre} versus measured FSI/ FSI_{pre} , and the Post-based prediction of FSI, derived from predicted NBR_{post} and measured NBR_{pre} , versus measured FSI.

independent training and test data sets. Viedma et al. (2020) uses a test dataset spatially independent from a train dataset to predict dNBR, RBR and RdNBR in a single fire at the Landsat and Sentinel-2 resolution (30 m and 10 m respectively). A decrease in forecasting performance between dNBR/RBR (R=0.84) and RdNBR (R=0.78) was observed in their work, but this decrease in forecasting performance was less pronounced than in our study. To the knowledge of the authors, no study has looked at predicting directly NBR_{post} , even though this index has already been used to assess fire severity (Escuin et al., 2008; Hudak et al., 2007; Miller et al., 2023).

3.1.2. Dependence to pre-fire conditions of forecasting performances

To examine the differences in forecasting performance between the FSI in more detail, let's look at the dependence of each FSI forecasting performance on the pre-fire conditions as suggested by Gale and Cary (2022). Figure 2 shows the linear regression of the forecasting performance (R, Difference-based prediction) vs the dependence of FSI on pre-fire conditions P, for the three difference FSI (dNBR, RBR, RdNBR). Here, P is the correlation between the predicted FSI_{pre} and the FSI. Results in Figure 2, where R is essentially an increasing linear function of P, indicate that the FSI forecasting performance is strongly related to the dependence of FSI on pre-fire conditions.

These results demonstrate that the forecasting performance of FSI in our dataset mainly results from the pre-fire component (FSI_{pre}) of each FSI, which is well predicted (see Section 3.1.1).

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

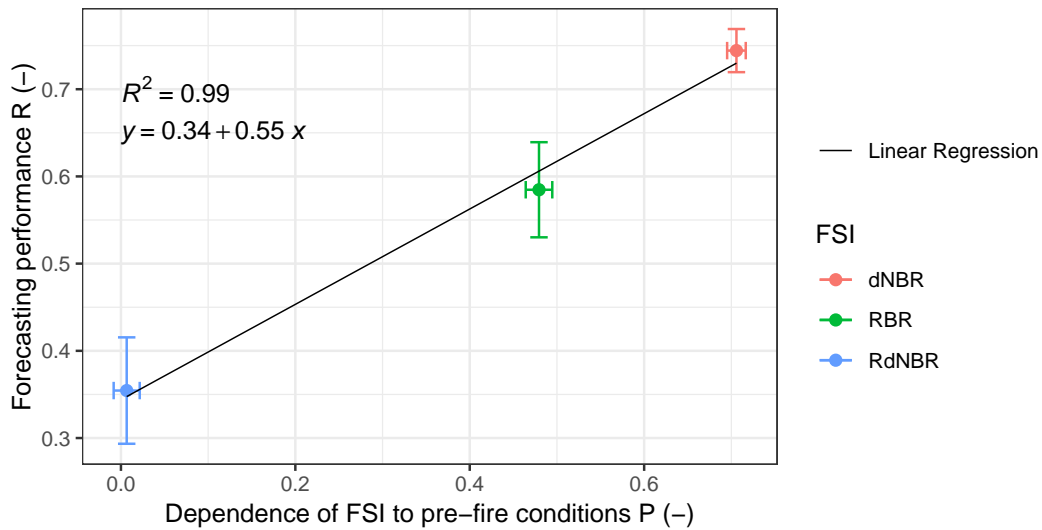


Figure 2: Scatterplot of predictive accuracy R (Difference-based prediction) versus the dependence of FSI on pre-fire conditions P (correlation between the predicted FSI_{pre} and the FSI). The length of the error bars is the standard deviation of P (horizontal) and R (vertical), and the coordinates of the points are the averages of P and R.




Figure 3: Boxplots of prediction model performance R per FSI and prediction method.

219 As a corollary, the post-fire component of FSI, which captures the post-fire information that was
 220 unknown before the fire, plays an important role in the unpredicted variance of FSI. This also
 221 shows that variations in forecasting performance between FSI do not reflect better performance
 222 of the indices in forecasting potential fire severity. Therefore, the prediction should focus on

1
2
3
4 223 the simplest FSI that does not integrate pre-fire information, i.e., NBR_{post} , to avoid any mislead-
5
6 224 ing interpretation in forecasting performance analysis. Additionally, deriving other FSI from the
7
8 225 predicted NBR_{post} and the satellite-derived NBR_{pre} could be a solution for working with known
9
10 226 indices (Post-based prediction).

11 12 227 3.2. Forecasting performance of Post-based prediction

13
14 228 In this Section, the forecasting performances of the Post-based FSI are compared with those
15
16 229 of the Difference-based FSI. Figure 3 shows the boxplots of R per FSI and prediction method
17
18 230 (Difference-based and Post-based predictions). Whatever the FSI, when it is derived from the pre-
19
20 231 dicted NBR_{post} and measured NBR_{pre} (Post-based), the forecasting performances are improved.
21
22 232 Table 1 presents the mean and standard deviation of forecasting performances (R) for the Post-
23
24 233 based predictions. A significant improvement is achieved for dNBR (R=0.78) and particularly for
25
26 234 RdNBR (R=0.43) – the relatively small standard deviations of the R-values calculated through the
27
28 235 cross-validation scheme indicate that these differences are clearly significant – and RBR reaches
29
30 236 almost the same forecasting performance (R=0.59). In addition, the order of forecasting perfor-
31
32 237 mances between the different FSI remains the same whatever the prediction method. For each
33
34 238 index, the RMSE remains constant or is even slightly improved when switching to Post-based
35
36 239 prediction (see Table 1).

37 240 We assume that this difference in forecasting performances between Difference-based predic-
38
39 241 tions and Post-based predictions is due to the prediction of NBR_{pre} that is not perfectly reproduced
40
41 242 by the prediction models (i.e., R values are relatively close to 1 but the prediction is less informa-
42
43 243 tive than the actual measured value of NBR_{pre}). Therefore, predicting the simplest post-fire FSI
44
45 244 (NBR_{post}) removes the mathematical and predictive issues of the other FSI (Parks et al., 2014),
46
47 245 while allowing to deduce them from the measured NBR_{pre} . Furthermore, these results reinforce
48
49 246 the fact that choosing an FSI based solely on its forecasting performance could be misleading:
50
51 247 different forecasting performances can be achieved among FSI with the same initial error resulting
52
53 248 from the inaccurate predictions of NBR_{post} .

4. Conclusion and recommendations

The forecasting performance of a Fire Severity Index (FSI) is defined as the correlation (R) between the predicted and satellite-derived FSI when the prediction is made at locations and times (Fire) different from those in the training sample. This approach assesses the model's ability to predict potential FSI in the near future. To date, the differences in forecasting performance of common FSI, such as dNBR, RBR, RdNBR, and NBR_{post} , derived from pre-fire optical and meteorological data, have not been clearly investigated. To address this gap, we predict these four indices at the fire-land cover spatial scale using widely available and recognized pre-fire remote sensing and meteorological predictors.

As a first assessment it is found that the forecasting performance strongly depends on the FSI and significantly differs across different FSI formulations. Then, we show that the forecasting performance of a FSI is mainly explained by its dependence to pre-fire conditions. As a consequence, variations in forecasting performance between FSI do not reflect better performance of the indices in forecasting potential severity. In addition, better forecasting performances of FSI can be achieved by deducing these indices using only the predicted NBR_{post} and the satellite-derived NBR_{pre} , since it avoids to imperfectly predict an already known pre-fire condition.

If there is a strong basis for assessing severity using FSI, we recommend not predicting potential severity from direct models (difference-based) of FSI. A simple post-fire FSI, such as the recognized NBR_{post} (García-Llamas et al., 2019), is sufficient for potential forecasting purposes. Therefore, we recommend that the predicted FSI be deduced from the predicted NBR_{post} and satellite-derived NBR_{pre} .

Disclosure statement

The authors report there are no competing interests to declare.

Data availability statement

The data that support the findings of this study are available from the corresponding author, VP, upon reasonable request.

1
2
3
4 **Funding**
5

6 276 This study was funded in part by the Horizon 2020 ACCWA project (grant agreement #
7
8 277 823965) in the context of Marie Skłodowska-Curie research and innovation staff exchange (RISE)
9
10 278 program.
11
12

13 **References**
14 279

- 15
16 280 Baetens, L., Desjardins, C., Hagolle, O., 2019. Validation of copernicus sentinel-2 cloud masks obtained from maja,
17
18 281 sen2cor, and fmask processors using reference cloud masks generated with a supervised active learning procedure.
19 282 Remote Sensing 11. URL: <https://www.mdpi.com/2072-4292/11/4/433>, doi:10.3390/rs11040433.
20
21 283 Barbero, R., Curt, T., Ganteaume, A., Maillé, E., Jappiot, M., Bellet, A., 2019. Simulating the effects of weather
22 284 and climate on large wildfires in france. Natural Hazards and Earth System Sciences 19, 441–454. URL: <https://nhess.copernicus.org/articles/19/441/2019/>, doi:10.5194/nhess-19-441-2019.
23
24 285
25 286 Birch, D.S., Morgan, P., Kolden, C.A., Abatzoglou, J.T., Dillon, G.K., Hudak, A.T., Smith,
26
27 287 A.M.S., 2015. Vegetation, topography and daily weather influenced burn severity in cen-
28
29 288 tral idaho and western montana forests. Ecosphere 6, art17. URL: <https://esajournals.onlinelibrary.wiley.com/doi/abs/10.1890/ES14-00213.1>,
30 289 doi:10.1890/ES14-00213.1,
31
32 290 arXiv:<https://esajournals.onlinelibrary.wiley.com/doi/pdf/10.1890/ES14-00213.1>.
33
34 291 Costa-Saura, J.M., Bacciu, V., Ribotta, C., Spano, D., Massaiu, A., Sirca, C., 2022. Predicting and mapping potential
35 292 fire severity for risk analysis at regional level using google earth engine. Remote Sensing 14. URL: <https://www.mdpi.com/2072-4292/14/19/4812>, doi:10.3390/rs14194812.
36
37 293
38 294 Elith, J., Leathwick, J.R., Hastie, T., 2008. A working guide to boosted regression trees. Journal of An-
39
40 295 imal Ecology 77, 802–813. URL: <https://besjournals.onlinelibrary.wiley.com/doi/abs/10.1111/j.1365-2656.2008.01390.x>,
41 296 doi:<https://doi.org/10.1111/j.1365-2656.2008.01390.x>,
42
43 297 arXiv:<https://besjournals.onlinelibrary.wiley.com/doi/pdf/10.1111/j.1365-2656.2008.01390.x>.
44
45 298 Epting, J., Verbyla, D., Sorbel, B., 2005. Evaluation of remotely sensed indices for assessing burn severity in interior
46 299 alaska using landsat tm and etm+. Remote Sensing of Environment 96, 328–339. doi:10.1016/j.rse.2005.03.
47
48 300 002.
49 301 Escuin, S., Navarro Cerrillo, R., Fernández, P., 2008. Fire severity assessment by using nbr (normalised burn ratio)
50
51 302 and ndvi (normalised difference vegetation index) derived from landsat tm/etm images. International Journal of
52
53 303 Remote Sensing 29, 1053–1073. doi:10.1080/01431160701281072.
54 304 Estes, B.L., Knapp, E.E., Skinner, C.N., Miller, J.D., Preisler, H.K., 2017. Factors influencing fire severity un-
55
56 305 der moderate burning conditions in the klamath mountains, northern california, usa. Ecosphere 8, e01794.
57
58
59
60
61
62
63
64
65

- 1
2
3
4 306 URL: <https://esajournals.onlinelibrary.wiley.com/doi/abs/10.1002/ecs2.1794>, doi:10.1002/
5 307 [ecs2.1794](https://esajournals.onlinelibrary.wiley.com/doi/pdf/10.1002/ecs2.1794), arXiv:<https://esajournals.onlinelibrary.wiley.com/doi/pdf/10.1002/ecs2.1794>.
6
7 308 Fang, L., Yang, J., White, M., Liu, Z., 2018. Predicting potential fire severity using vegetation, topography and
8 309 surface moisture availability in a eurasian boreal forest landscape. *Forests* 9. URL: [https://www.mdpi.com/](https://www.mdpi.com/1999-4907/9/3/130)
9 310 [1999-4907/9/3/130](https://www.mdpi.com/1999-4907/9/3/130), doi:10.3390/f9030130.
11 311 Fang, L., Yang, J., Zu, J., Li, G., Zhang, J., 2015. Quantifying influences and relative importance of fire
12 312 weather, topography, and vegetation on fire size and fire severity in a chinese boreal forest landscape. *For-*
13 313 *est Ecology and Management* 356, 2–12. URL: [https://www.sciencedirect.com/science/article/pii/](https://www.sciencedirect.com/science/article/pii/S0378112715000134)
14 314 [S0378112715000134](https://www.sciencedirect.com/science/article/pii/S0378112715000134), doi:10.1016/j.foreco.2015.01.011. special Section: The characteristics, impacts and
15 315 management of forest fire in China.
16 316 Fernández-García, V., Beltrán-Marcos, D., Fernández-Guisuraga, J.M., Marcos, E., Calvo, L., 2022. Predicting
17 317 potential wildfire severity across southern europe with global data sources. *Science of The Total Environment* 829,
18 318 154729. URL: <https://www.sciencedirect.com/science/article/pii/S0048969722018228>, doi:10.
19 319 1016/j.scitotenv.2022.154729.
20 320 Gale, M., Cary, G., 2022. What determines variation in remotely sensed fire severity? consideration of remote sensing
21 321 limitations and confounding factors. *International Journal of Wildland Fire* 31, 291–305. doi:10.1071/WF21131.
22 322 García-Llamas, P., Suárez-Seoane, S., Fernández-Guisuraga, J.M., Fernández-García, V., Fernández-Manso, A.,
23 323 Quintano, C., Taboada, A., Marcos, E., Calvo, L., 2019. Evaluation and comparison of landsat 8, sentinel-2 and
24 324 deimos-1 remote sensing indices for assessing burn severity in mediterranean fire-prone ecosystems. *International*
25 325 *Journal of Applied Earth Observation and Geoinformation* 80, 137–144. URL: [https://www.sciencedirect.](https://www.sciencedirect.com/science/article/pii/S030324341930176X)
26 326 [com/science/article/pii/S030324341930176X](https://www.sciencedirect.com/science/article/pii/S030324341930176X), doi:<https://doi.org/10.1016/j.jag.2019.04.006>.
27 327 González-Alonso, F., de Miguel, S.M., Roldán-Zamarrón, A., García-Gigorro, S., Gozalo, J.M.C., 2006. Forest
28 328 biomass estimation through ndvi composites. the role of remotely sensed data to assess spanish forests as carbon
29 329 sinks. *International Journal of Remote Sensing* 27, 5409–5415. URL: 10.1080/01431160600830748, doi:10.
30 330 1080/01431160600830748, arXiv:10.1080/01431160600830748.
31 331 Hagolle, O., Dedieu, G., Mougenot, B., Debaecker, V., Duchemin, B., Meygret, A., 2008. Correction of aerosol effects
32 332 on multi-temporal images acquired with constant viewing angles: Application to formosat-2 images. *Remote*
33 333 *Sensing of Environment* 112, 1689–1701. URL: [https://www.sciencedirect.com/science/article/pii/](https://www.sciencedirect.com/science/article/pii/S0034425707004130)
34 334 [S0034425707004130](https://www.sciencedirect.com/science/article/pii/S0034425707004130), doi:10.1016/j.rse.2007.08.016. remote Sensing Data Assimilation Special Issue.
35 335 Hagolle, O., Huc, M., Pascual, D., Dedieu, G., 2010. A multi-temporal method for cloud detection, applied to
36 336 formosat-2, venus, landsat and sentinel-2 images. *Remote Sensing of Environment* 114, 1747–1755. doi:10.
37 337 1016/j.rse.2010.03.002.
38 338 Hagolle, O., Huc, M., Villa Pascual, D., Dedieu, G., 2015. A multi-temporal and multi-spectral method to estimate
39 339 aerosol optical thickness over land, for the atmospheric correction of formosat-2, landsat, venus and sentinel-2

- 1
2
3
4 340 images. *Remote Sensing* 7, 2668–2691. URL: <https://www.mdpi.com/2072-4292/7/3/2668>, doi:10.3390/
5 341 rs70302668.
- 6
7 342 Hudak, A., Morgan, P., Bobbitt, M., Smith, A., Lewis, S., Lentile, L., Robichaud, P., Clark, J., McKinley, R., 2007.
8 343 The relationship of multispectral satellite imagery to immediate fire effects. *Fire Ecology* 3, 64–90. doi:10.4996/
9 344 fireecology.0301064.
- 10
11 345 Jain, T.B., Graham, R.T., 2007. The relation between tree burn severity and forest structure in the rocky mountains,
12 346 in: *Restoring fire-adapted ecosystems: Proceedings of the 2005 national silviculture workshop*. Tahoe City, CA.
13 347 Albany, CA. USDA Forest Service. Pacific Southwest Research Station, pp. 213–250.
- 14
15
16 348 Keeley, J., 2009. Fire intensity, fire severity and burn severity: A brief review and suggested usage. *International*
17 349 *Journal of Wildland Fire* 18, 116–126. doi:10.1071/WF07049.
- 18
19 350 Key, C.H., Benson, N.C., 2005. Landscape Assessment (LA) Sampling and Analysis Methods *in* Lutes, Duncan C.;
20 351 Keane, Robert E.; Caratti, John F.; Key, Carl H.; Benson, Nathan C.; Sutherland, Steve; Gangi, Larry J. 2006.
21 352 FIREMON: Fire effects monitoring and inventory system. Gen. Tech. Rep. RMRS-GTR-164-CD. Fort Collins,
22 353 CO: U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station. pp. LA 1–51.
- 23
24 354 Kuhn, M., 2008. caret: Classification and Regression Training. URL: [https://cran.r-project.org/web/
25 355 packages/caret/index.html](https://cran.r-project.org/web/packages/caret/index.html), doi:10.32614/CRAN.package.caret.
- 26
27 356 Lentile, L., Holden, Z., Smith, A., Falkowski, M., Hudak, A., Morgan, P., Lewis, S., Gessler, P., Benson, N., 2006. Re-
28 357 mote sensing techniques to assess active fire characteristics and post-fire effects. *International Journal of Wildland*
29 358 *Fire* 15, 319–345. doi:10.1071/WF05097.
- 30
31
32 359 Li, Y., Robinson, S.V., Nguyen, L.H., Liu, J., 2023. Satellite prediction of coastal hypoxia in the northern gulf of
33 360 mexico. *Remote Sensing of Environment* 284, 113346. URL: [https://www.sciencedirect.com/science/
34 361 article/pii/S0034425722004527](https://www.sciencedirect.com/science/article/pii/S0034425722004527), doi:10.1016/j.rse.2022.113346.
- 35
36
37 362 López García, M.J., Caselles, V., 1991. Mapping burns and natural reforestation using thematic mapper data. *Geocarto*
38 363 *International* 6, 31–37. doi:10.1080/10106049109354290.
- 39
40 364 Marion, G.M., Moreno, J.M., Oechel, W.C., 1991. Fire severity, ash deposition, and clipping effects on soil nutrients in
41 365 chaparral. *Soil Science Society of America Journal* 55, 235–240. doi:[https://doi.org/10.2136/sssaj1991.
42 366 03615995005500010040x](https://doi.org/10.2136/sssaj1991.03615995005500010040x).
- 43
44
45 367 Miller, C., Harvey, B., Kane, V., Moskal, L., Alvarado, E., 2023. Different approaches make comparing studies of
46 368 burn severity challenging: a review of methods used to link remotely sensed data with the composite burn index.
47 369 *International Journal of Wildland Fire* 32, 449–475. doi:10.1071/WF22050.
- 48
49
50 370 Miller, J., Thode, A., 2007. Quantifying burn severity in a heterogeneous landscape with a relative version of the delta
51 371 normalized burn ratio (rdnbr). *Remote Sensing of Environment* 109, 66–80. doi:10.1016/j.rse.2006.12.006.
- 52
53
54 372 Parks, S.A., Dillon, G.K., Miller, C., 2014. A new metric for quantifying burn severity: The relativized burn ra-
55 373 tio. *Remote Sensing* 6, 1827–1844. URL: <https://www.mdpi.com/2072-4292/6/3/1827>, doi:10.3390/
56
57
58
59
60
61
62
63
64
65

1
2
3
4 374 rs6031827.

5 375 Parks, S.A., Holsinger, L.M., Koontz, M.J., Collins, L., Whitman, E., Parisien, M.A., Loehman, R.A., Barnes, J.L.,
6
7 376 Bourdon, J.F., Boucher, J., Boucher, Y., Caprio, A.C., Collingwood, A., Hall, R.J., Park, J., Saperstein, L.B.,
8
9 377 Smetanka, C., Smith, R.J., Soverel, N., 2019. Giving ecological meaning to satellite-derived fire severity metrics
10 378 across north american forests. *Remote Sensing* 11. URL: <https://www.mdpi.com/2072-4292/11/14/1735>,
11 379 doi:10.3390/rs11141735.

12
13 380 Parks, S.A., Holsinger, L.M., Panunto, M.H., Jolly, W.M., Dobrowski, S.Z., Dillon, G.K., 2018a. High-severity fire:
14 381 evaluating its key drivers and mapping its probability across western us forests. *Environmental Research Letters*
15 382 13, 044037. URL: <https://dx.doi.org/10.1088/1748-9326/aab791>, doi:10.1088/1748-9326/aab791.

16 383 Parks, S.A., Holsinger, L.M., Voss, M.A., Loehman, R.A., Robinson, N.P., 2018b. Mean composite fire severity
17 384 metrics computed with google earth engine offer improved accuracy and expanded mapping potential. *Remote*
18 385 *Sensing* 10. URL: <https://www.mdpi.com/2072-4292/10/6/879>, doi:10.3390/rs10060879.

19 386 Pimont, F., Fargeon, H., Opitz, T., Ruffault, J., Barbero, R., Martin-StPaul, N., Rigolot, E.,
20 387 RiviÉre, M., Dupuy, J.L., 2021. Prediction of regional wildfire activity in the probabilis-
21 388 tic bayesian framework of firelihood. *Ecological Applications* 31, e02316. URL: <https://esajournals.onlinelibrary.wiley.com/doi/abs/10.1002/eap.2316>,
22 389 doi:10.1002/eap.2316,
23 390 arXiv:<https://esajournals.onlinelibrary.wiley.com/doi/pdf/10.1002/eap.2316>.

24 391 Price, O.F., Bradstock, R.A., 2012. The efficacy of fuel treatment in mitigating property loss during wildfires:
25 392 Insights from analysis of the severity of the catastrophic fires in 2009 in victoria, australia. *Journal of Envi-*
26 393 *ronmental Management* 113, 146–157. URL: [https://www.sciencedirect.com/science/article/pii/](https://www.sciencedirect.com/science/article/pii/S0301479712004574)
27 394 [S0301479712004574](https://www.sciencedirect.com/science/article/pii/S0301479712004574), doi:<https://doi.org/10.1016/j.jenvman.2012.08.041>.

28 395 Ridgeway, G., 2006. GBM: Generalized boosted regression models. URL: [https://cran.r-project.org/web/](https://cran.r-project.org/web/packages/gbm/index.html)
29 396 [packages/gbm/index.html](https://cran.r-project.org/web/packages/gbm/index.html), doi:10.32614/CRAN.package.gbm.

30 397 Shakesby, R.A., Chafer, C., Doerr, S.H., Blake, W.H., Wallbrink, P., Humphreys, G., Harrington, B.A., 2003. Fire
31 398 severity, water repellency characteristics and hydrogeomorphological changes following the christmas 2001 sydney
32 399 forest fires. *Australian Geographer* 34, 147–175. doi:10.1080/00049180301736.

33 400 Stephens, S.L., Moghaddas, J.J., Edminster, C., Fiedler, C.E., Haase, S., Harrington, M., Kee-
34 401 ley, J.E., Knapp, E.E., McIver, J.D., Metlen, K., Skinner, C.N., Youngblood, A., 2009. Fire
35 402 treatment effects on vegetation structure, fuels, and potential fire severity in western u.s.
36 403 forests. *Ecological Applications* 19, 305–320. URL: [https://esajournals.onlinelibrary.](https://esajournals.onlinelibrary.wiley.com/doi/abs/10.1890/07-1755.1)
37 404 [wiley.com/doi/abs/10.1890/07-1755.1](https://esajournals.onlinelibrary.wiley.com/doi/abs/10.1890/07-1755.1),
38 405 doi:<https://doi.org/10.1890/07-1755.1>,
39 406 arXiv:<https://esajournals.onlinelibrary.wiley.com/doi/pdf/10.1890/07-1755.1>.

40 407 Taylor, A.H., Harris, L.B., Drury, S.A., 2021. Drivers of fire severity shift as landscapes transi-
41 408 tion to an active fire regime, klamath mountains, usa. *Ecosphere* 12, e03734. URL: <https://doi.org/10.1002/ecsp.407>.

- 1
2
3
4 408 //esajournals.onlinelibrary.wiley.com/doi/abs/10.1002/ecs2.3734, doi:10.1002/ecs2.3734,
5 409 arXiv:https://esajournals.onlinelibrary.wiley.com/doi/pdf/10.1002/ecs2.3734.
6
7 410 Van Wagner, C., et al., 1987. Development and structure of the Canadian forest fire weather index system. volume 35.
8
9 411 Veraverbeke, S., Rogers, B.M., Randerson, J.T., 2015. Daily burned area and carbon emissions from boreal fires in
10 412 alaska. *Biogeosciences* 12, 3579–3601. doi:10.5194/bg-12-3579-2015.
11
12 413 Vidal, J.P., Martin, E., Franchistéguy, L., Baillon, M., Soubeyroux, J.M., 2010. A 50-year high-resolution at-
13 414 mospheric reanalysis over france with the safran system. *International Journal of Climatology* 30, 1627–
14 415 1644. URL: <https://rmets.onlinelibrary.wiley.com/doi/abs/10.1002/joc.2003>, doi:10.1002/
16 416 joc.2003, arXiv:https://rmets.onlinelibrary.wiley.com/doi/pdf/10.1002/joc.2003.
17
18 417 Viedma, O., Chico, F., Fernández, J., Madrigal, C., Safford, H., Moreno, J., 2020. Disentangling the role of prefire
19 418 vegetation vs. burning conditions on fire severity in a large forest fire in se spain. *Remote Sensing of Environ-*
20 419 *ment* 247, 111891. URL: <https://www.sciencedirect.com/science/article/pii/S0034425720302613>,
22 420 doi:10.1016/j.rse.2020.111891.
24 421 Viedma, O., Quesada, J., Torres, I., Santis, A., Moreno, J., 2014. Fire severity in a large fire in a pinus pinaster
25 422 forest is highly predictable from burning conditions, stand structure, and topography. *Ecosystems* 18, 237–250.
27 423 doi:10.1007/s10021-014-9824-y.
28
29 424 Wang, X., Wotton, B.M., Cantin, A., Parisien, M.A., Anderson, K., Moore, B., Flannigan, M.D., 2017. cff-
30 425 drs: An r package for the canadian forest fire danger rating system. *Ecological Processes* 6, 5. URL:
32 426 <https://ecologicalprocesses.springeropen.com/articles/10.1186/s13717-017-0070-z>, doi:10.
33 427 1186/s13717-017-0070-z.
35 428 Wells, A.G., Hawbaker, T.J., Hiers, J.K., Kean, J., Loehman, R.A., Steblein, P.F., 2019. Predicting burn severity
36 429 for integration with post-fire debris-flow hazard assessment: a case study from the upper colorado river basin,
38 430 usa. *International Journal of Wildland Fire* 32, 1315–1331. URL: [https://www.publish.csiro.au/paper/](https://www.publish.csiro.au/paper/WF22200)
40 431 [WF22200](https://www.publish.csiro.au/paper/WF22200), doi:10.1071/WF22200.
41
42 432 Zhu, X., Liu, D., 2015. Improving forest aboveground biomass estimation using seasonal landsat ndvi time-series.
43 433 *ISPRS Journal of Photogrammetry and Remote Sensing* 102, 222–231. URL: [https://www.sciencedirect.](https://www.sciencedirect.com/science/article/pii/S0924271614002202)
44 434 [com/science/article/pii/S0924271614002202](https://www.sciencedirect.com/science/article/pii/S0924271614002202), doi:10.1016/j.isprsjprs.2014.08.014.
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

Chapitre 5

Combinaison des données satellitaires optiques/thermiques Landsat et de hauteur de canopée pour estimer le stress hydrique et les flux turbulents dans les forêts méditerranéennes

5.1 Introduction

L'estimation du stress hydrique et des flux turbulents (H et LE) à partir de la LST dans des milieux semi-arides, en particulier forestiers, demeure un défi. Une des hypothèse est la difficulté à prendre en compte la rugosité des couverts dans les approches de référence utilisant la LST . L'approche contextuelle $LST-f_{vg}$ ne prend qu'indirectement les effets de rugosité en compte, au travers de f_{vg} . L'hypothèse sous-jacente, qui fonctionne pour de faibles hauteurs de couvert (inférieure à 1-2 m), est qu'il existe une relation strictement monotone entre f_{vg} et rugosité (Long and Singh, 2012; Long et al., 2012; Moran et al., 1994; Sun et al., 2017). Cette hypothèse est mise en défaut dans les milieux à la structure hétérogène comme les forêts méditerranéennes. Par ailleurs, la disponibilité et la couverture spatiale croissantes des données LiDAR haute définition permettent d'estimer des métriques de structure de la canopée (IGN, 2024; Potapov et al., 2021; Schwartz et al., 2024) à la résolution spatiale courante des satellites (eg missions comme Landsat (100 m)) dont la hauteur du couvert (hc), proxy de la rugosité. Cette étude développe une nouvelle approche basée sur la méthode contextuelle classique $LST-f_{vg}$ et des données LiDAR, pour estimer le stress hydrique et les flux turbulents en forêt méditerranéenne. Dans une première Section 5.2, le matériel et les méthodes sont présentés puis les résultats sont discutés (Section 5.3). Enfin la Section 5.4 conclut et ouvre des perspectives. Toute cette étude s'appuie sur un article détaillé, disponible en Section 5.5.

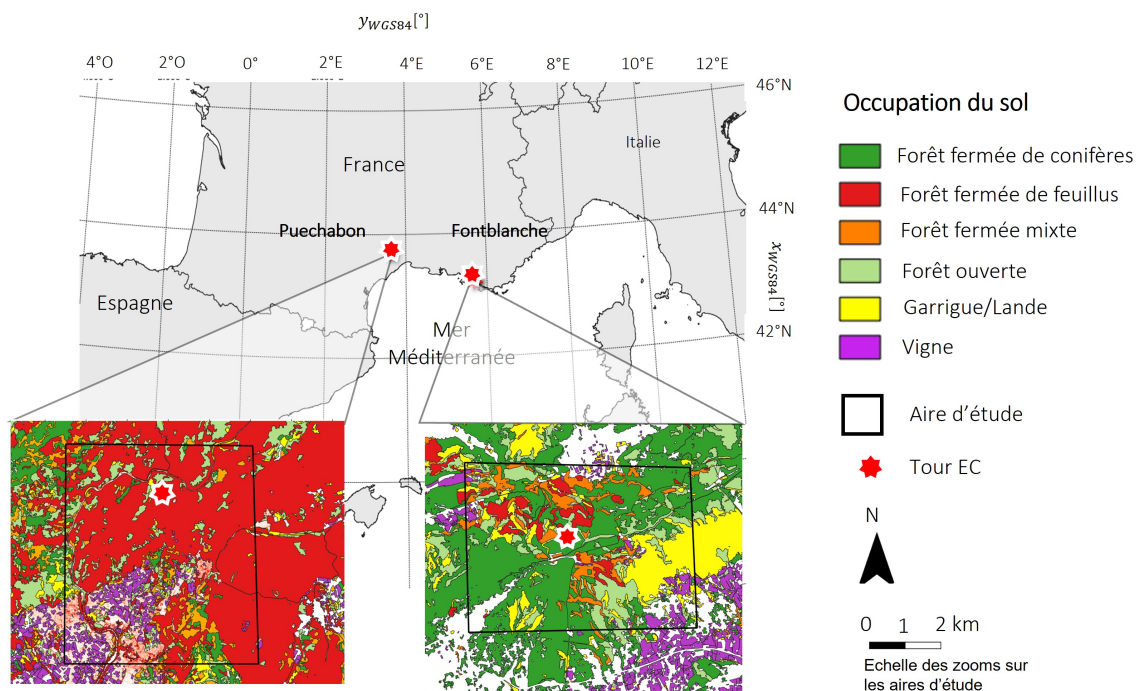


FIGURE 5.1 – Localisation des deux sites Eddy Covariance et des aires d'étude (Puechabon à gauche et Fontblanche à droite). L'occupation du sol est fournie par l'IGN.

5.2 Matériel et méthodes

5.2.1 Sites et aires d'études de Puechabon et Fontblanche

Le site de Puechabon est une forêt composée d'un taillis dense de chênes verts, avec une hauteur dominante de 5.5 m et d'un sous-étage d'arbustes d'environ 2 m (Ollivier et al., 2021). Le site connaît une température annuelle moyenne de 14.7 °c et des précipitations annuelles moyennes de 895 mm. Le site de Fontblanche est situé dans une forêt méditerranéenne à l'est de Marseille. Les espèces dominantes sont le pin d'Alep (hauteur de 13 m), et le chêne vert (hauteur de 5 m) (Ollivier et al., 2021). La température annuelle moyenne est de 14.3 °c et les précipitations annuelles moyennes sont de 676 mm. Les deux sites sont équipés d'une tour à flux par Eddy Covariance qui mesure les grandeurs météorologiques (T_{air} , Rh , Ws , Rg) et les flux (Rn , LE , H) intégrés sur un intervalle de 30 minutes. Autour de chaque tour à flux, deux aires d'études de 6400 et 5164 ha pour Puechabon et Fontblanche respectivement sont dessinées, de façon à minimiser l'amplitude d'altitude en leur sein et de maximiser la diversité des occupations du sol (voir figure 5.1).

5.2.2 Données météorologiques et de télédétection

Les données météorologiques (T_{air} , Rh , Ws et flux courte longueur d'onde entrant Rg) proviennent des mesures in situ et sont supposées uniformes dans l'ensemble des aires d'études. Dans le cadre d'une analyse de sensibilité sur la qualité des données météorologiques, les données de réanalyse SAFRAN sont utilisées (excepté Rg , données in situ).

Les données optiques/thermiques proviennent des missions Landsat-7/8/9 et fournissent f_{vg} et LST . Les données LiDAR proviennent de la mission haute définition de l'IGN (IGN, 2024) et, après traitement, fournissent une hc à la résolution Landsat (Martin-Ducup et al., 2025). Ces trois données sont extraites sur l'ensemble des deux aires d'études (LST et f_{vg} d'avril à octobre 2014-2021 et d'avril à août 2022

pour Puechabon et d'avril à octobre 2013-2021 pour Fontblanche).

5.2.3 Estimation de EF et des flux turbulents

Trois approches sont utilisées pour estimer EF (EF_{sat}) puis les flux turbulents (LE_{sat} , H_{sat}). La figure 5.2 résume l'ensemble des approches, à savoir $LST - f_{vg}$, $LST_{norm} - f_{vg}(Tsd_{context})$ et $LST_{norm} - f_{vg}(Tsd_{EB})$.

Approche de référence pour estimer EF

L'approche de référence est $LST - f_{vg}$ (voir figure 5.2 à gauche). EF est estimée par la méthode contextuelle classique $LST - f_{vg}$ appliquée aux deux aires d'étude de Fontblanche et Puechabon (voir Section 2.3.3).

Normalisation des effets de hc sur la LST

La décroissance de la LST avec hc ("effets de hc ") quantifiable grâce au nuage de points LST vs hc (espace contextuel $LST - hc$), permet de définir une hc maximale (hc_{max} , voir figure 5.2 au centre en haut). hc_{max} est la hauteur telle que si hc est supérieure à hc_{max} alors la LST n'est plus couplée aux flux turbulents. La médiane des hc_{max} toute dates confondues est appelée Hc_{max} et peut être calculée par site ou pour tous les sites. Hc_{max} est utilisée pour normaliser LST des effets de hc (LST_{norm}). LST_{norm} est la température équivalente à LST pour $hc = 0$ et est calculée selon l'expression :

$$LST_{norm} = LST + \frac{hc}{Hc_{max}}(Tsd_{context} - T_{air}) \quad (5.1)$$

avec $Tsd_{context}$, la température maximale observable avant et après normalisation de la LST .

Estimation de EF dans l'espace $LST_{norm} - f_{vg}$

Dans l'espace contextuel $LST_{norm} - f_{vg}$, le bord sec est supposé plat. Au premier ordre, les effets de rugosité dont un proxy est hc , impliquent une décroissance de la LST avec f_{vg} (Sun et al., 2017) : la rugosité de la surface est généralement beaucoup plus faible pour un sol nu que pour une couverture végétale complète (voir figure 2.9). Une fois la température normalisée des effets de hc , il n'y a plus de décroissance de la LST avec f_{vg} . Deux approches sont alors possibles pour fixer l'ordonnée à l'origine du bord sec plat (voir figure 5.2 au centre et à droite).

La première approche, $LST_{norm} - f_{vg}(Tsd_{context})$, utilise la température de sol nu sec contextuelle ($Tsd_{context}$) déterminée à l'étape précédente comme ordonnée à l'origine du bord sec (commune aux espaces $LST_{norm} - f_{vg}$ et $LST - hc$).

La seconde approche, $LST_{norm} - f_{vg}(Tsd_{EB})$, utilise une température de sol nu sec simulée par un modèle bilan d'énergie. Dans certaines conditions, en particulier humides, l'absence de conditions sèches à la résolution du capteur du satellite peut entraîner une sous-estimation de $Tsd_{context}$. Utiliser un modèle bilan d'énergie pour estimer la température de sol nu sec permet de pallier ce problème (Long et al., 2012). Le modèle bilan d'énergie requiert l'utilisation de données météorologiques (T_{air} , Rg , Rh , Ws), d'une paramétrisation de la rugosité de surface du sol nu (constante fixée à $z_{0m} = 0.003$ m pour les deux sites) et du ratio de G sur Rn du sol nu ($G/Rn = 0.32$ pour les deux sites).

Estimation des flux turbulents

Une première étape consiste à estimer le flux net Rn à partir des données météorologiques (T_{air} , Rh , Rg) et de la LST . Les flux turbulents sont alors calculés à partir de Rn estimé et de EF_{sat} pour chacune des trois approches (voir figure 5.2 en bas).

5.2.4 Évaluation des résultats

Les données in situ de Rn , H (H_{insitu}), LE (LE_{insitu}) et EF (EF_{insitu}) évaluées à partir des mesures des tours à flux servent de références. Elles sont utilisées pour l'évaluation des mêmes grandeurs estimées à partir des mesures satellitaires (Voir figure 5.2 en bas).

5.2.5 Analyse de sensibilité

L'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ requière des données météorologiques et une paramétrisation supplémentaires par rapport à l'approche $LST - f_{vg}$. Afin d'étudier la robustesse de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$, une analyse de sensibilité est menée sur les données et paramètres suivants : Hc_{max} , données météorologiques (SAFRAN au lieu de in situ) et le ratio G/Rn . Deux valeurs de Hc_{max} sont considérées pour chacun des sites : soit la valeur calculée pour tous les sites, soit la valeur calculée par site. Les données météorologiques in situ sont supposées plus précises que les données SAFRAN. Aussi ce dernier jeu de données est utilisé pour évaluer la sensibilité de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ à des données météorologiques moins précises. La normalisation des effets de hc ne normalise pas de la différence de conduction entre le sol nu ($G/Rn = 0.32$) et la végétation pleinement couvrante ($G/Rn = 0$). Par défaut, le modèle bilan d'énergie simule une température de sol nu, soit $G/Rn = 0.32$. La valeur $G/Rn = 0$ est prise comme valeur pour analyser la sensibilité de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ à ce paramètre. Quel que soit le paramètre ou le jeu de données, les flux turbulents sont estimés pour différentes valeurs de ces paramètres/données et l'évolution des métriques de qualité est analysée.

5.3 Résultats et discussion

5.3.1 Normalisation des effets de hc

Les valeurs de hc_{max} sont toujours positives, ce qui illustre la diminution de la LST avec hc . hc_{max} est la valeur de hc telle si hc est supérieure à hc_{max} alors la LST n'est plus couplée aux flux turbulents. Les variations de hc_{max} sont assez faibles (interquartiles de 22 m et 12 m pour Puechabon et Fontblanche respectivement) ce qui laisse supposer que Hc_{max} est une valeur stable au sein d'une aire d'étude. Les Hc_{max} sont du même ordre de grandeur entre les deux sites : 50 m pour Puechabon et 39 m pour Fontblanche. La valeur de Hc_{max} calculée pour les deux sites est 43 m.

5.3.2 Estimation de EF et des flux turbulents

La figure 5.3 montre les nuages de points des flux turbulents, H et LE , et de EF dérivés de données satellitaires et des données météorologiques in situ vs les flux et EF dérivés des mesures in situ. Seuls les résultats pour $Hc_{max} = 43$ m (valeur commune aux deux sites Eddy Covariance) sont présentés ici.

Tout d'abord, l'approche $LST - f_{vg}$ (figure 5.3 (a)) donne des estimations de H/LE très biaisées (biais = $-162 \text{ W.m}^{-2} / 132 \text{ W.m}^{-2}$ pour H/LE) et sous-estime particulièrement les hautes valeurs de H et faibles valeurs de LE . Ces résultats sont cohérents avec la bibliographie. Par ailleurs les structures des erreurs de l'estimation de EF sont distinctes entre chaque site, les nuages de points de EF_{sat} vs

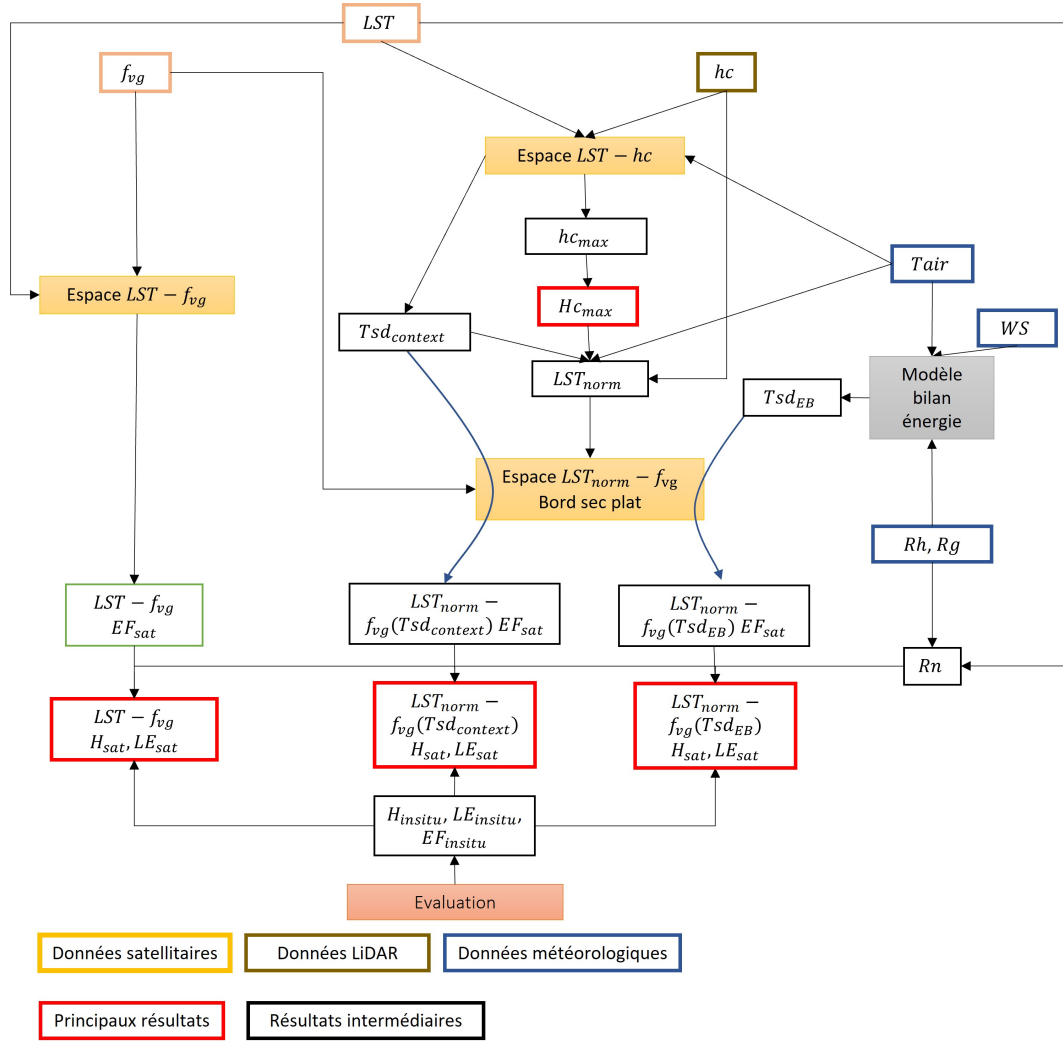


FIGURE 5.2 – Schéma résumant les approches pour 1) estimer EF par l'approche de référence $LST - f_{vg}$ (gauche), 2) normaliser la LST des effets de hc (haut à droite) et 3) utiliser un bord sec plat fixé à une température de sol nu sec estimée contextuellement ($LST_{norm} - f_{vg}(Tsd_{context})$, au centre) ou par un modèle bilan d'énergie ($LST_{norm} - f_{vg}(Tsd_{EB})$, à droite). Les flux turbulents sont ensuite calculés à partir d'un Rn estimé et des EF estimées par les trois approches. Ils sont évalués au regard des flux et EF dérivés des mesures in situ (bas).

EF_{insitu} étant distincts. En particulier, le biais est 3 fois plus important à Fontblanche qu'à Puechabon. Les différences de structure de la canopée entre les deux sites pourraient expliquer des tendances d'erreur différentes entre les deux sites (eg la hauteur du couvert dominant à Puechabon est 2.4 fois inférieure à celle de Fontblanche).

La normalisation des effets de hc et l'approche $LST_{norm} - f_{vg}(Tsd_{context})$ (figure 5.3 (b)) améliore la corrélation de H/LE ($R = 0.72 / 0.36$), mais pas le biais qui reste important ($-161 \text{ W.m}^{-2} / 130 \text{ W.m}^{-2}$). Par ailleurs les tendances des erreurs d'estimation de EF sont similaires pour les deux sites, les nuages de points pour EF étant confondus (biais = $0.25 / 0.22$ pour EF à Puechabon/Fontblanche). Dès lors, les différences de structure de la canopée entre les deux sites sont indépendantes de l'analyse et de la correction de l'erreur qui sont désormais communes aux deux sites.

La normalisation des effets de hc et l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ (figure 5.3 (c)) augmente la sensibilité (pente) des flux et EF estimés et réduit le biais ($-30 \text{ W.m}^{-2} / -1 \text{ W.m}^{-2} / 0.01$ pour $H/LE/EF$). Cette avancée est intéressante car le modèle bilan d'énergie dispose des mêmes valeurs de paramètres

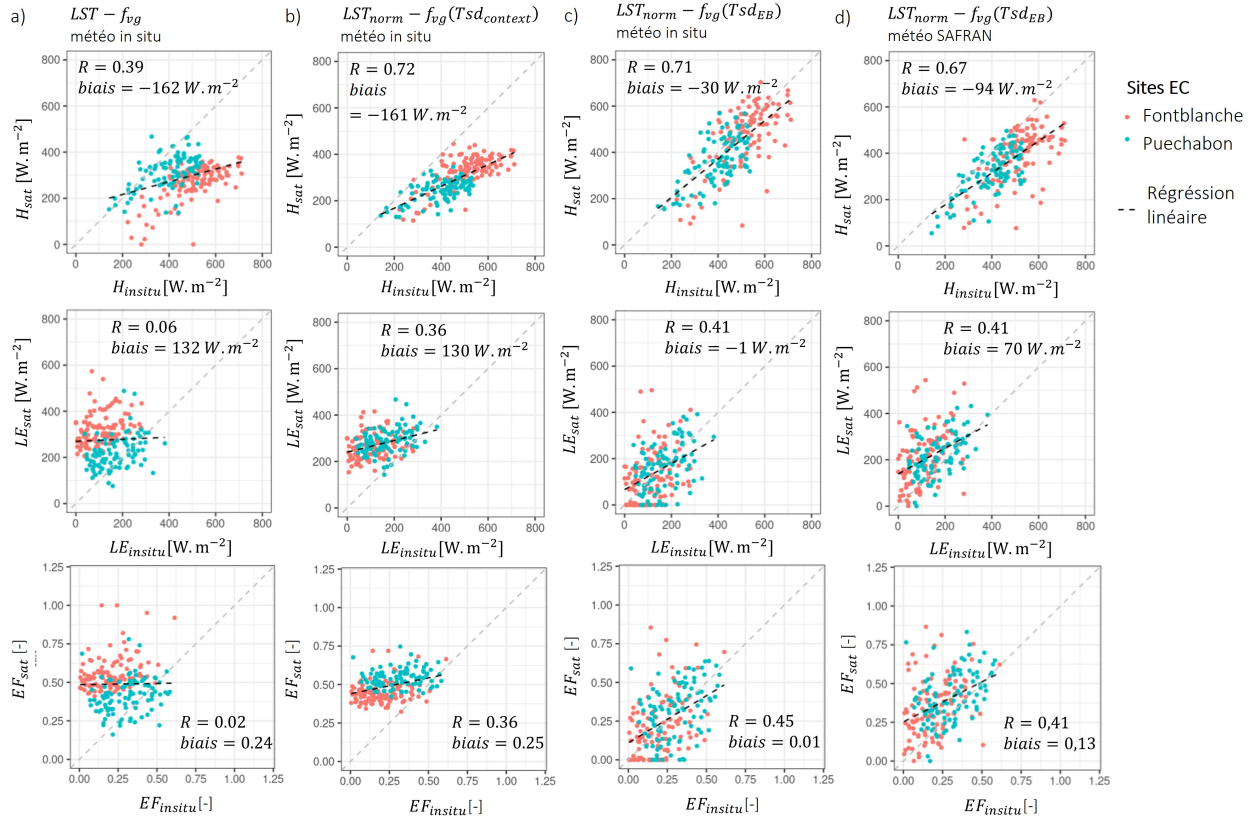


FIGURE 5.3 – Nuage de points de H , LE et EF dérivés des données satellitaires vs H , LE et EF in situ pour l'ensemble des sites, en utilisant l'approche $LST - f_{vg}$ et les données météorologiques in situ (a), l'approche $LST_{norm} - f_{vg}(Tsd_{context})$ et les données météorologiques in situ (b), l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ et les données météorologiques in situ (c) et l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ et les données météorologiques SAFRAN (d).

pour les deux sites, bien que les structures de canopée soient différentes. Au regard de la bibliographie, c'est la première fois que cette qualité de résultats est obtenue pour les deux sites en même temps. Certains aspects restent à néanmoins approfondir. La justification physique de l'utilisation d'un modèle bilan d'énergie se base sur l'hypothèse d'une sous-estimation moyenne de Tsd_{EB} par $Tsd_{context}$ (voir Section 5.2.3). Tsd_{EB} réintroduit bien les dynamiques des conditions météorologiques dans le bord sec de l'espace $LST_{norm} - f_{vg}$ ($R = 0.92$ pour Tsd_{EB} vs $Tsd_{context}$). Pourtant Tsd_{EB} sous-estime $Tsd_{context}$ (biais de -5.5 K entre Tsd_{EB} et $Tsd_{context}$). Ce biais implique une diminution du biais absolu sur EF , H et LE . Cette sous-estimation de la température de sol nu sec solutionnerait une sous-estimation de LST sur forêt que la normalisation des effets de hc ne prend pas entièrement en compte.

5.3.3 Analyse de sensibilité

L'analyse de sensibilité menée sur Hc_{max} (estimation des flux avec $Hc_{max} = 43$ m pour les deux aires d'étude vs $Hc_{max} = 50$ m pour Puechabon et $Hc_{max} = 39$ m pour Fontblanche) montre que l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ est très robuste (pas ou peu de variation de R). En particulier, la faible sensibilité des estimations de H , LE et EF à Hc_{max} laisse supposer qu'une valeur commune (≈ 40 m) peut exister pour les deux aires d'étude. L'analyse de sensibilité effectuée sur les données météorologiques montre la robustesse de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$. Les flux H et LE ainsi que EF estimés avec des données météorologiques moins précises (SAFRAN) que les données in situ conservent une qualité proche

de celle de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ (données météorologiques in situ, voir figure 5.3 (d)) et une meilleure qualité que celles des approches $LST - f_{vg}$ et $LST_{norm} - f_{vg}(Tsd_{context})$ (données météorologiques in situ). L'analyse de sensibilité menée sur le paramètre G/Rn n'induit pas d'évolution significative de R et induit une légère diminution de la sensibilité (pente). La réintroduction de la variabilité temporelle du forçage météorologique est donc conservée. Le biais absolu augmente (variation absolue de -70 W.m^{-2} pour H et 73 W.m^{-2} pour LE sur l'ensemble des deux sites Eddy Covariance) ce qui est physiquement cohérent (biais de -2.7 K entre Tsd_{EB} pour $G/Rn = 0$ et $Tsd_{context}$).

5.4 Conclusion

L'utilisation combinée de données optiques/thermiques et de hc dérivées du LiDAR sur deux sites forestiers méditerranéens permet d'inférer l'existence d'une hauteur H_{cmax} au-delà de laquelle la LST n'est plus couplée aux flux turbulents et qui serait constante dans le temps et dans l'espace ($\approx 40 \text{ m}$). La méthode de référence $LST - f_{vg}$ produit des estimations de H , LE et EF très biaisées et peu corrélées aux données in situ sur les deux sites Eddy Covariance, dont les structures de canopée (hc) diffèrent. L'utilisation de H_{cmax} permet de normaliser la LST des effets de hc . Le résultat est LST_{norm} , équivalente à LST pour $hc = 0$. Les utilisations de LST_{norm} dans l'espace contextuel $LST_{norm} - f_{vg}$ et d'un bord sec plat déterminé contextuellement permettent d'améliorer la corrélation pour H , LE et EF . Cette approche produit des tendances d'erreurs d'estimation de EF communes aux deux sites et indépendantes des différences de structure de canopée entre les deux sites. Finalement, l'utilisation d'un bord sec plat estimé par un modèle bilan d'énergie réintroduit les dynamiques temporelles des conditions météorologiques dans le bord sec de l'espace $LST_{norm} - f_{vg}$ (approche $LST_{norm} - f_{vg}(Tsd_{EB})$). Il résulte de cette approche une amélioration significative (augmentation de la pente et réduction du biais) des estimations de H , LE et EF pour les deux sites en même temps. L'analyse de sensibilité montre que l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ est peu sensible à des variations de paramètres (H_{cmax} , G/Rn) ou de qualité de données météorologiques.

Si l'ensemble de ces étapes permettent une amélioration significative de l'estimation des flux turbulents et de EF par rapport à l'approche classique $LST - f_{vg}$, il est important de noter que cette étude n'a été menée que sur deux sites. L'extension de l'approche à d'autres sites forestiers semi-arides permettrait de confirmer sa robustesse. Enfin, une sous-estimation de la température de sol nu sec observée par la température simulée par le modèle bilan d'énergie met en lumière l'importance d'autres facteurs qui affectent la forêt (sous-estimation de la LST). Ces facteurs de variation de la LST indépendants du stress hydrique ne sont pas pris en compte par la normalisation des effets de hc . Plusieurs voies de recherche sont envisagées. Tout d'abord LST_{norm} est l'équivalente de la LST pour $hc = 0$. Cependant la rugosité n'est pas l'unique grandeur différenciant le sol nu de la végétation. Les caractéristiques radiatives (émissivité, albédo) ou encore le paramètre G/Rn diffèrent (Kustas and Daughtry, 1990). Une meilleure compréhension et interprétation du sens physique de LST_{norm} pourrait permettre de mieux contraindre la paramétrisation du modèle bilan d'énergie. D'autre part, la sous-estimation de la LST sur forêt pourrait être expliquée par l'"effet convectif de la canopée" (Banerjee et al., 2017; Rotenberg and Yakir, 2010, 2011). Ces auteurs considèrent les forêts comme des convecteurs d'énergie turbulente efficaces, surtout en conditions sèches. Enfin, les effets directionnels à l'échelle sub-pixellaire du satellite pourraient aussi expliquer la sous-estimation de la LST sur forêt (Michel et al., 2023).

5.5 Article associé : "Combining Landsat optical/thermal and LiDAR HD data to estimate turbulent fluxes over Mediterranean forests"

Remote Sensing of Environment

Combining Landsat optical/thermal and LiDAR HD data to estimate turbulent fluxes over Mediterranean forests

--Manuscript Draft--

Manuscript Number:	
Article Type:	Research Paper
Section/Category:	Land surface energy and water balance
Keywords:	Turbulent fluxes; thermal remote sensing; Mediterranean forest; LiDAR; contextual methods
Corresponding Author:	Victor Penot Center for the Study of the Biosphere from Space FRANCE
First Author:	Victor Penot
Order of Authors:	Victor Penot Olivier Merlin
Abstract:	<p>The performance of thermal-based models to estimate sensible (H) and latent (LE) heat fluxes over semi-arid forests has been poorly documented, due to the difficulty of representing the impact of canopy height (h_c) and aerodynamic resistance on the remotely sensed land surface temperature (LST). To fill the gap, this study integrates LiDAR-derived h_c in the classical contextual method combining Landsat-derived LST and green fraction cover (fvg). In practice, Landsat LST is normalized for the effect of h_c and the normalized LST is used in the classical contextual method to estimate H and LE. The approach is tested during a nine-year period over two Mediterranean forest areas of 6400 ha and 5164 ha, namely Puechabon and Fontblanche, including two eddy covariance stations for validation. The extrapolated h_c value (named h_{cmax}) above which LST is no more sensitive to turbulent fluxes is estimated as $h_{cmax}=50 \pm 7$ m for Puechabon and $h_{cmax}=39 \pm 4.5$ m for Fontblanche. For both sites, the normalization of LST for h_c effect significantly improves the correlation between remotely sensed and in situ H (LE) measurements from 0.39 (0.06) to 0.72 (0.36), respectively. Moreover, by setting the dry edge to the maximum temperature simulated by a simple soil energy balance model, the bias between remotely sensed and in situ H (LE) measurements is much reduced from -162 (+132) W.m⁻² to -30 (-1) W.m⁻², respectively. It is the first time that LiDAR-derived h_c has been used to improve thermal-derived turbulent flux estimates.</p>
Opposed Reviewers:	

1 Highlights

2 **Combining Landsat optical/thermal and LiDAR HD data to estimate turbulent fluxes over**

3 **Mediterranean forests**

4 Victor Penot, Olivier Merlin

- 5 • A canopy height of over about 40 m decouples *LST* from turbulent fluxes
- 6 • Classical contextual method fails to estimate turbulent fluxes in Mediterranean forests
- 7 • Normalizing *LST* for canopy height effect improves contextual method performance
- 8 • Performance is further improved by simulating the dry edge using an EB model

[Click here to view linked References](#)

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

1 Highlights

2 **Combining Landsat optical/thermal and LiDAR HD data to estimate turbulent fluxes over** 3 **Mediterranean forests**

4 Victor Penot, Olivier Merlin

- 5 • A canopy height of over about 40 m decouples *LST* from turbulent fluxes
- 6 • Classical contextual method fails to estimate turbulent fluxes in Mediterranean forests
- 7 • Normalizing *LST* for canopy height effect improves contextual method performance
- 8 • Performance is further improved by simulating the dry edge using an EB model

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

Combining Landsat optical/thermal and LiDAR HD data to estimate turbulent fluxes over Mediterranean forests

Victor Penot^a, Olivier Merlin^a

^aUniversite de Toulouse, CNES/CNRS/IRD/INRAe, CESBio, 18 avenue Edouard Belin, Toulouse, 31401, France

Abstract

The performance of thermal-based models to estimate sensible (H) and latent (LE) heat fluxes over semi-arid forests has been poorly documented, due to the difficulty of representing the impact of canopy height (hc) and aerodynamic resistance on the remotely sensed land surface temperature (LST). To fill the gap, this study integrates LiDAR-derived hc in the classical contextual method combining Landsat-derived LST and green fraction cover (f_{vg}). In practice, Landsat LST is normalized for the effect of hc and the normalized LST is used in the classical contextual method to estimate H and LE . The approach is tested during a nine-year period over two Mediterranean forest areas of 6400 ha and 5164 ha, namely Puechabon and Fontblanche, including two eddy covariance stations for validation. The extrapolated hc value (named hc_{max}) above which LST is no more sensitive to turbulent fluxes is estimated as $hc_{max} = 50 \pm 7$ m for Puechabon and $hc_{max} = 39 \pm 4.5$ m for Fontblanche. For both sites, the normalization of LST for hc effect significantly improves the correlation between remotely sensed and in situ H (LE) measurements from 0.39 (0.06) to 0.72 (0.36), respectively. Moreover, by setting the dry edge to the maximum temperature simulated by a simple soil energy balance model, the bias between remotely sensed and in situ H (LE) measurements is much reduced from -162 ($+132$) $W.m^{-2}$ to -30 (-1) $W.m^{-2}$, respectively. It is the first time that LiDAR-derived hc has been used to improve thermal-derived turbulent flux estimates.

Keywords: Turbulent fluxes, thermal remote sensing, Mediterranean forest, LiDAR, contextual methods

Email address: victor.penot@iut-tlse3.fr (Victor Penot)

Preprint submitted to Remote Sensing of Environment

March 7, 2025

1. Introduction

Around the world, forests are threatened by climate change, which is imposing rapid changes and more intense meteorological forcing (Dyderski et al., 2018; Hartmann et al., 2022). Forests in the Mediterranean region suffer from increasing drought and prolonged heat waves, although they are accustomed to long periods of high temperature and low rainfall (Alderotti et al., 2024; Ameztegui et al., 2024; Peñuelas et al., 2017). Therefore, monitoring the health of these forests over large areas is of paramount importance to forest managers and public policy-makers.

Among the key results of forest health assessment, those related to water fluxes are highly relevant, as they can be used as an early warning of possible dieback (Castellaneta et al., 2022; Colangelo et al., 2017). Plants can dissipate the received solar energy by transpiration, quantified by the latent heat flux (LE [$\text{W}\cdot\text{m}^{-2}$]), or by heat convection through their canopy, quantified by the sensible heat flux (H [$\text{W}\cdot\text{m}^{-2}$]) (Jones and Rotenberg, 2011). LE and H are related to each other by the surface energy balance, since their sum approximately equals the net available energy on forests (Jones and Rotenberg, 2011). Satellite remote sensing offers a good trade-off between large spatial coverage, high spatial resolution and high revisit frequency, and therefore appears suitable for monitoring forest health. In particular, the optical/thermal spectrum provides complementary information on land use/land cover and can be used to estimate turbulent fluxes, namely LE and H (Boulet et al., 2015; Moran et al., 1994; Trebs et al., 2021).

Two distinct approaches have been used to estimate turbulent heat fluxes from land surface temperature (LST) data, namely the energy balance (EB) models and the semi-empirical contextual methods. For three decades, these two approaches have been applied intensively and extensively to relatively low (height of 1-2 m max.) vegetation cover (Chirouze et al., 2014; Delogu et al., 2018; Hu et al., 2023), but much more rarely to forest cover (Trebs et al., 2021; Vidal and Devaux-Ros, 1995).

EB models derive H as the solution of a system of physical equations whose inputs are meteorological and LST data (Boulet et al., 2015; Su, 2002) and estimate LE as the residual term of the EB. The vast majority of EB models operate at the pixel level and use the Monin-Obukhov similarity theory to express key parameters describing the influence of surface geometry on tur-

1
2
3
4 60 bulent fluxes (via aerodynamic resistance), namely zero-plane displacement height and roughness
5 61 heights for heat and momentum (Boulet et al., 2015; Su, 2002; Trebs et al., 2021). In this physi-
6
7 62 cal approach, zero-plane displacement and roughness heights particularly influence aerodynamic
8
9 63 resistance through their interaction with wind speed and are explicitly expressed as a function of
10
11 64 several canopy parameters including canopy height (hc), leaf area index (LAI) and frontal area
12
13 65 index (González-Dugo et al., 2021; Maurer et al., 2015; Shaw and Pereira, 1982; Tian et al., 2011;
14
15 66 Trebs et al., 2021). Thus, EB modelling requires intensive parameterisation at the pixel level (Chi-
16
17 67 rouze et al., 2014; Delogu et al., 2018) to account for forest structure and then to retrieve turbulent
18
19 68 fluxes from LST . This calibration problem is all the more pronounced in the case of Mediter-
20
21 69 ranean forests, which present a high degree of structural heterogeneity (sparse or dense tree cover
22
23 70 of different heights, shrubs) (Bottalico et al., 2017).

24
25 71 In addition to the difficulty of parameterizing the aerodynamic resistance in a wide range of
26
27 72 conditions, EB models tend to overestimate LE and underestimate H in arid and semi-arid areas
28
29 73 (Burchard-Levine et al., 2022; Gokmen et al., 2012; Gokool et al., 2020; Hu et al., 2023; van der
30
31 74 Kwast et al., 2009; Morillas et al., 2013). Few studies have investigated the retrieval of H/LE from
32
33 75 EB modelling over forests in water-limited conditions. Trebs et al. (2021) evaluated H and LE
34
35 76 using three different EB models: Soil Plant Atmosphere and Remote Sensing Evapotranspiration
36
37 77 (SPARSE), Surface Energy Balance System (SEBS) and Surface Temperature Initiated Closure
38
39 78 (STIC). All three models were fed with LST and LAI from Moderate-Resolution Imaging Spec-
40
41 79 troradiometer (MODIS) satellites and in situ meteorological and radiation measurements. They
42
43 80 studied nine Australian forest and shrubland sites with both a gradient of hc (ranging from 3.0 m
44
45 81 to 40.0 m), LAI (ranging from $0.15 \text{ m}^2 \cdot \text{m}^{-2}$ to $4.9 \text{ m}^2 \cdot \text{m}^{-2}$) and a gradient of ecoregions (rang-
46
47 82 ing from dry desert and xeric shrublands to moister tropical savannas), including Mediterranean
48
49 83 (semi-arid) woodlands. They showed that water-limited (arid/semi-arid) sites exhibit a strong un-
50
51 84 derestimation of H and thus a strong overestimation of LE (up to 50% on average). Such biases in
52
53 85 H and LE were not present at the wetter energy-limited (mesic) sites. These results were latterly
54
55 86 confirmed by Bartkowiak et al. (2024), who indicated a negative correlation ($R = -0.18$) between
56
57 87 satellite and in situ LE measurements at a French Mediterranean site (Puechabon) using the two-
58
59 88 source energy balance (TSEB) model fed with Sentinel-3 LST data. Another recent example is

1
2
3
4 89 provided by Njuki et al. (2023), who used the SEBS model and documented an underestimation
5 90 of H for forest sites (including the Puechabon site). One of the assumptions for such errors is that
6
7 91 under high hydric stress, forests are very efficient in transporting heat fluxes from the surface to
8
9 92 the atmosphere (Banerjee et al., 2017; Njuki et al., 2023), and the current aerodynamic resistance
10
11 93 and roughness parameterisation are not suitable to account for this (Adeline et al., 2024; Burchard-
12
13 94 Levine et al., 2021; Trebs et al., 2021). The use of current EB modelling for turbulent heat fluxes
14
15 95 retrieval is therefore limited in forest areas, especially those subject to drought.

16
17 96 As an alternative to EB models, contextual methods use the semi-empirical spatial relationship
18
19 97 between LST and a satellite-derived vegetation index to derive the evaporative fraction (EF) (Jiang
20
21 98 and Islam, 1999; Moran et al., 1994; Wang et al., 2006). The fractional green vegetation cover
22
23 99 (f_{vg}) is often used as vegetation index (Chirouze et al., 2014; Merlin, 2013) in the so-called LST -
24
25 100 f_{vg} feature space to weight the EF (LST) relationship from bare soil to full-cover conditions
26
27 101 (Chirouze et al., 2014). This approach requires the estimation of boundary i.e. dry ($LE \approx 0$)
28
29 102 and wet ($H \approx 0$) conditions from bare soil ($f_{vg} = 0$) to full vegetation cover ($f_{vg} = 1$). In practice,
30
31 103 assuming that the wet and dry boundary conditions evolve almost linearly between $f_{vg} = 0$ and f_{vg}
32
33 104 $= 1$ (Moran et al., 1994), this problem is reduced to find four temperature endmembers that define
34
35 105 the dry and wet edges of the LST - f_{vg} space. These dry and wet temperature endmembers are
36
37 106 either estimated statistically from the observed surface conditions within a sufficiently wide study
38
39 107 area (Merlin, 2013; Tang et al., 2010) or simulated by an EB model (Long and Singh, 2012; Long
40
41 108 et al., 2012; Moran et al., 1994; Stefan et al., 2015; Sun et al., 2017). Note that in both cases,
42
43 109 meteorological data are assumed to be uniform within the study area. In addition, the statistical
44
45 110 approach for estimating temperature endmembers assumes that dry and wet extreme conditions
46
47 111 are present and observed at the sensor resolution (Merlin, 2013; Stisen et al., 2008).

48
49 112 Contextual methods have been shown to be effective on crops (Chirouze et al., 2014; Mer-
50
51 113 lin, 2013; Tang et al., 2010) and their simplicity makes them promising for operational use over
52
53 114 extended areas (Gallego-Elvira et al., 2013). However, classical contextual methods do not con-
54
55 115 sider the impact of surface roughness on LST . Especially, the variability of hc within the study
56
57 116 area is neglected, or it is assumed to be strongly correlated with the vegetation index used to
58
59 117 form the feature space with LST observations. The point is that, over natural landscapes such as

1
2
3
4 118 Mediterranean forests, it is very likely that the same f_{vg} values correspond to very different canopy
5 119 structures (different roughness and hc values). Current contextual methods should therefore fail in
6
7 120 landscapes with heterogeneous canopy structure and hc (Adeline et al., 2024; Penot and Merlin,
8
9 121 2023).

10
11 122 At the same time, the increasing availability and spatial coverage of high-resolution (HD)
12
13 123 Light Detection And Ranging (LiDAR) data allows the determination of canopy structure metrics,
14
15 124 especially the simplest one, hc , at common satellite spatial resolution (IGN, 2024; Potapov et al.,
16
17 125 2021; Schwartz et al., 2024). LiDAR data are not suitable to monitor the hc of crops because they
18
19 126 are not updated frequently enough, but they are deemed suitable to estimate the hc of forests on
20
21 127 relatively short time scales (<10 years). New high-resolution LiDAR monitoring capabilities pave
22
23 128 the way for integrating these data into evapotranspiration and EB models.

24
25 129 Currently, few studies have utilized LiDAR-derived canopy metrics for estimating turbulent
26
27 130 fluxes from EB models. Khan et al. (2021) incorporated hc data from the Ice, Cloud, and land
28
29 131 Elevation Satellite/Geoscience Laser Altimeter System into the SEBS model to estimate LE us-
30
31 132 ing LST data from the Landsat missions. This study focused on three wet forest sites in East
32
33 133 and Southeast Asia, with in situ hc values of 8.10, 13.00, and 15.00 m, and estimated hc values
34
35 134 of 10.34, 16.20, and 17.50 m. The findings highlighted that hc is a crucial parameter that can
36
37 135 introduce uncertainties in SEBS model estimations. Additionally, using LiDAR-derived hc data
38
39 136 improved the estimation of H , reducing the root mean square error ($RMS E$) by up to 47% (though
40
41 137 with a mean bias of -69.43 W.m^{-2}), and enhanced the correlation coefficient for LE by up to 9%.
42
43 138 Ma et al. (2022) used the Geoscience Laser Altimeter System LiDAR-derived hc as an input pa-
44
45 139 rameter to the SEBS model in southwest China, but they did not compare their results with SEBS
46
47 140 estimates without LiDAR-derived hc information. Aboutalebi et al. (2020) utilized drone-derived
48
49 141 metrics at very high spatial resolution to evaluate the sensitivity of the TSEB model. They com-
50
51 142 pared the use of mean/nominal values in footprints against the spatial distribution of fractional
52
53 143 canopy cover, hc ranging from 0 to 1.5 m, and canopy width information within a 3.6-m grid. This
54
55 144 study was conducted over two vineyards (two flux towers) and involved four flights in Califor-
56
57 145 nia. The results demonstrated that incorporating spatially-distributed canopy structure parameters
58
59 146 significantly improved the agreement between TSEB model outputs for H and LE with tower mea-

1
2
3
4 147 surements, reducing the *RMS E* by 58% for *H* and 46% for *LE*. Similarly, Neale et al. (2011) used
5 148 very high (1-m) resolution LiDAR-derived *hc* data as input in two EB models (TSEB and Surface
6
7 149 Energy Balance Algorithm for Land (SEBAL)) to study water use among riparian species.

8
9 150 The above literature review indicates that very few studies have used spatialized estimates of
10
11 151 *hc* (e.g. from LiDAR data) to account for *hc* variability in estimating turbulent heat fluxes, and
12
13 152 of these, none has focused on the dry/semi-arid environment. Given the complexity of spatial-
14
15 153 ized parameterization of aerodynamic resistance in EB models over relatively dry forests and the
16
17 154 high sensitivity of model outputs to this parameterization, this study develops a new methodology
18
19 155 based on the classical contextual method. The proposed approach normalizes the Landsat *LST*
20
21 156 for *hc* effect and replaces *LST* by the normalized *LST* (LST_{norm}) in the classical feature space.
22
23 157 Specifically, this paper aims to (i) quantitatively assess the effect of *hc* on *LST* over extended
24
25 158 areas, (ii) develop a normalisation method of Landsat *LST* for *hc* effect, and (iii) evaluate the
26
27 159 Landsat-derived *H* and *LE* estimates obtained from the new ($LST_{norm}-f_{vg}$) and the classical (*LST*-
28
29 160 f_{vg}) contextual method. To achieve these objectives, the study focuses on two Mediterranean sites,
30
31 161 differing in their vegetation structure, in southern France, where in situ flux measurements are
32
33 162 available for a nine-year period. Section 2 describes the study areas, the in situ and remote sensing
34
35 163 data used and presents the methodology to normalise *LST* for *hc* effect. Section 3 presents and
36
37 164 discusses the results obtained by the normalisation of *LST* and by the different methods in terms
38
39 165 of *H* and *LE* estimates. Finally, Section 4 summarises the main findings and paves the way for
40
41 166 future research.

42 43 167 **2. Material and Methods**

44
45 168 In this Section, the study area and the eddy-covariance (EC) sites (Section 2.1) and the re-
46
47 169 motely sensed and meteorological data used (Section 2.2) are first presented. Then, the principle
48
49 170 and basic assumptions of the classical contextual method to estimate *EF* are briefly reminded
50
51 171 (Section 2.3). Next, the new contextual method is described (Section 2.4), by relying on the nor-
52
53 172 malization of *LST* for *hc* effect. Section 2.5 presents the estimation of turbulent fluxes from *EF*
54
55 173 estimates of both (classical and new) approaches. Finally, a method for analysing the sensitivity
56
57 174 of the new approach to its input data is proposed (Section 2.5).

1
2
3
4 175 2.1. Study areas

5 176 2.1.1. Eddy covariance sites

7 177 The Puechabon site (43°44'29"N; 3°35'46"E, 270 m a.s.l., see Figure 1) is an evergreen
8
9
10 178 broadleaf forest characterized by dense coppice. The dominant tree species is the holm oak (*Quer-*
11 179 *cus Ilex* L.), with an average height of 5.5 m, while the understory consists of sparse shrubs about
12
13 180 2 m high (Ollivier et al., 2021). The site experiences a mean annual temperature of 14.7 °C and
14
15 181 an average annual precipitation of 895 mm, with significant intra-annual variations. Summers are
16
17 182 typically dry and hot, whereas heavy rainfall occurs mainly in the fall and spring. For illustration,
18
19 183 Figure 2 (a) shows the monthly cumulative rainfall and the monthly mean air temperature from
20
21 184 2013 to 2022. The soil at Puechabon is silty clay loam, with a rock and stone volumetric content
22
23 185 of 75% in the top 50 cm and 90% throughout the entire profile (Rambal et al., 2003). Despite the
24
25 186 soil's poor water retention (Ollivier et al., 2021), it has been demonstrated that *Quercus Ilex* can
26
27 187 extract water from depths greater than 4 m during drought conditions (Allard et al., 2008; Rambal
28
29 188 et al., 2003).

30 189 The Fontblanche site is located in a mixed Mediterranean forest in south-eastern France (43°14'27"N,
31
32 190 5°40'45"E; 425 m a.s.l.). The two dominant tree species are Aleppo pine (*Pinus halepensis*) in
33
34 191 the upper tree stratum, 13-m high, and holm oak (*Quercus Ilex*) in the intermediate stratum, 5-m
35
36 192 high (Ollivier et al., 2021). Both species show different functional strategies to cope with drought
37
38 193 (Moreno et al., 2024; Vicente et al., 2018) that can be related to *LST*. On the one hand, Aleppo
39
40 194 pine is said drought avoidant as it closes its stomata at a relatively high water potential, corre-
41
42 195 sponding to the water potential inducing full stomatal closure. On the other hand, holm oak is said
43
44 196 drought tolerant as it delays stomatal regulation. The mean annual temperature is 14.3 °C and the
45
46 197 mean annual precipitation is 676 mm with strong intra annual variations (see 2 (b)). The soil, a
47
48 198 silty clay loam, has a maximum depth of around 50 cm, and a volumetric rock fraction of about
49
50 199 50% at the top, and up to 90% at the bottom (Ollivier et al., 2021) while the bedrock is karstified
51
52 200 limestone.

53 201 Both sites have been active in monitoring Mediterranean forests in the context of climate
54
55 202 change. The Puechabon site has gained a lot of scientific interest during the previous years, re-
56
57 203 garding the monitoring and modelling of turbulent fluxes. An increasing number of studies have

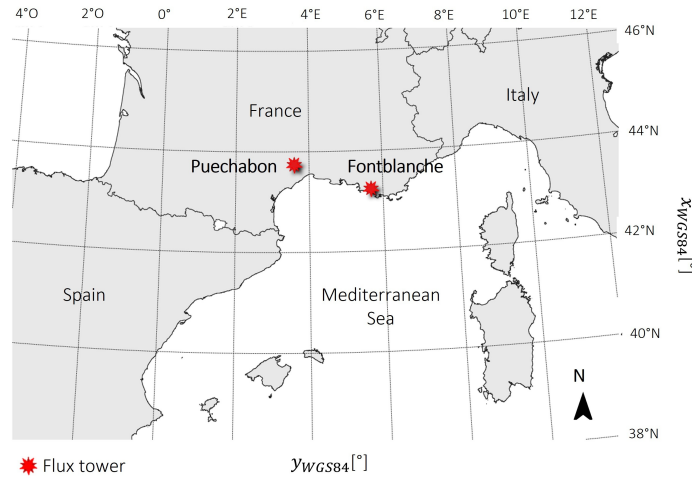


Figure 1: Map of the location of the two EC sites.

204 been undertaken at the Puechabon EC site using 1 km resolution MODIS/Sentinel-3 thermal data
 205 (Bartkowiak et al., 2024; Hu et al., 2015; Jiang and Ryu, 2016; Ryu et al., 2012), using 100 m
 206 resolution Landsat thermal data (Penot and Merlin, 2023), or to evaluate different models of turbu-
 207 lent fluxes (STIC, Community Land Model (CLM) 5.0, SEBS)(Mallick et al., 2024; Njuki et al.,
 208 2023). The Fontblanche site has been more confidential in terms of modelling and monitoring
 209 turbulent fluxes, since there is no published study on the use of remotely sensed thermal data. It
 210 is however a dynamic site in terms of water balance/flux modelling (Ollivier et al., 2021; Simioni
 211 et al., 2016) and studies of mixed canopy in the context of climate change (Simioni et al., 2013,
 212 2020, 2016).

2.1.2. *In situ measurements*

214 Both sites are equipped with an EC flux measurement system that continuously monitors me-
 215 teorological data (relative humidity (RH [-]), air temperature (T_{air} [K]), wind speed (WS [$m \cdot s^{-1}$]),
 216 solar radiation (R_g [$W \cdot m^{-2}$])) and surface energy fluxes (LE , H and net radiation (R_n , [$W \cdot m^{-2}$])) at
 217 12 m and 17 m height (for Puechabon and Fontblanche respectively) every 30 minutes. Flux and
 218 meteorological data from 2014 to august 2022 (Puechabon) and from 2013 to 2021 (Fontblanche)
 219 were downloaded from the European Fluxes Database Cluster and Integrated Carbon Observation
 220 System database. The instantaneous Bowen ratio (β_{insitu} [-]) is defined as the ratio between H and

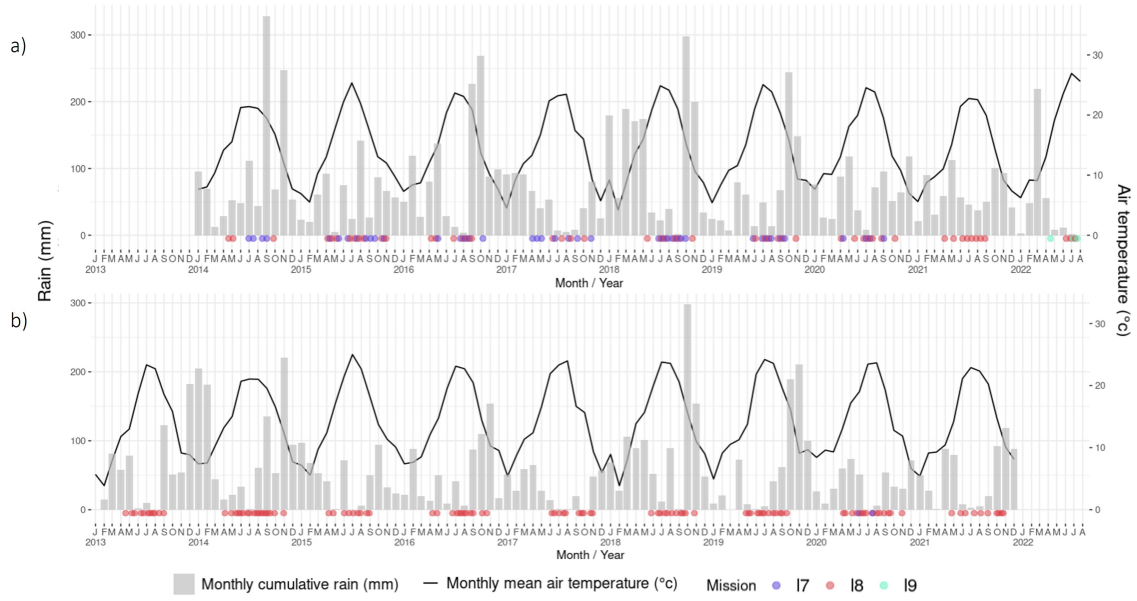


Figure 2: Monthly cumulative rain, monthly mean temperature and Landsat satellite mission (7/8/9) overpass dates during the study periods at Puechabon (a) and Fontblanche (b) site.

LE instantaneous in situ measurements, at the satellite overpass time (Crago and Brutsaert, 1996).

The instantaneous in situ *EF* [-] is expressed from the β_{insitu} as Crago and Brutsaert (1996):

$$EF_{insitu} = \frac{1}{1 + \beta_{insitu}} \quad (1)$$

To check the quality of *EF*_{insitu}, we calculate the daily Bowen Ratio βd_{insitu} , a value that is assumed constant during daytime. βd_{insitu} is the ratio of the sum of in situ *H* from 8 a.m. to 3 p.m. by the sum of in situ *LE* from 8 a.m. to 3 p.m. Jiang et al. (2009). The daytime in situ *EF* (*EF*_{d_{insitu}}) is estimated by means of βd_{insitu} (1). *EF*_{insitu} evaluated against *EF*_{d_{insitu}} shows a good quality: the correlation is 0.97/0.93 and the slope is 0.99/1 for the Puechabon/Fontblanche EC site, respectively. Hence the instantaneous *EF*_{insitu} is kept as a reference value. In situ flux observations are corrected using the Bowen ratio method for closing the EB as in Trebs et al. (2021):

$$H_{insitu} = \frac{\beta_{insitu} Rn_{insitu}}{1 + \beta_{insitu}} \quad (2)$$

$$LE_{insitu} = \frac{Rn_{insitu}}{1 + \beta_{insitu}} \quad (3)$$

With Rn_{insitu} [$\text{W}\cdot\text{m}^{-2}$] the net radiation measured at the flux tower.

2.1.3. Study areas

For both sites, a study area is selected so that meteorological conditions around the EC tower can be considered to be relatively homogeneous, including topographical conditions that are unlikely to affect T_{air} (adiabatic gradient) significantly. It must also offer the widest possible range of land cover characteristics, from bare soil to a fully vegetated surface. Figure 3 presents the two selected study areas surrounding the Puechabon ((a) and (b)) and Fontblanche ((c) and (d)) EC sites. Background images in Figure 3 correspond to Spot 6-7 visible images acquired in 2023 and the natural land cover map provided by the French National Geographic Institute (IGN) (BD Topo – 2016). The Puechabon and Fontblanche areas are 6400 ha and 5164 ha, respectively. The Puechabon study area is covered with closed broad leaf forest (Holm oak), as next to the EC site. The remaining of the area is covered with open forest and vineyard. The great majority of the surface of the Fontblanche study area is covered with closed coniferous forest (Aleppo pines), as encountered next to the EC site, which generally has a greater average height than closed Mediterranean broadleaf forest and shrublands. For both sites, the white area (in the land cover map) is covered with roads, urban areas, or quarries. The average, minimum and maximum elevation is 192 m, 40 m and 518 m, and 322 m, 79 m and 563 m for Puechabon and Fontblanche respectively.

2.1.4. Spatialized meteorological data

Two meteorological datasets are used in this study. The meteorological measurements at the EC station are interpolated at the satellite overpass hour. As a first approximation, they are assumed to be representative of the meteorological conditions within the whole study area. As an alternative to station-based measurements, the SAFRAN reanalysis dataset is also used for RH , T_{air} , and WS . The SAFRAN reanalysis dataset (Vidal et al., 2010) provides hourly meteorological data on an 8-km grid. T_{air} , WS (at 10 m height) and RH are linearly interpolated and averaged over the whole study area at the satellite overpass hour. The R_g is provided by EC-site measurements only. The two (in situ and SAFRAN) meteorological data sets for T_{air} , WS and RH are

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

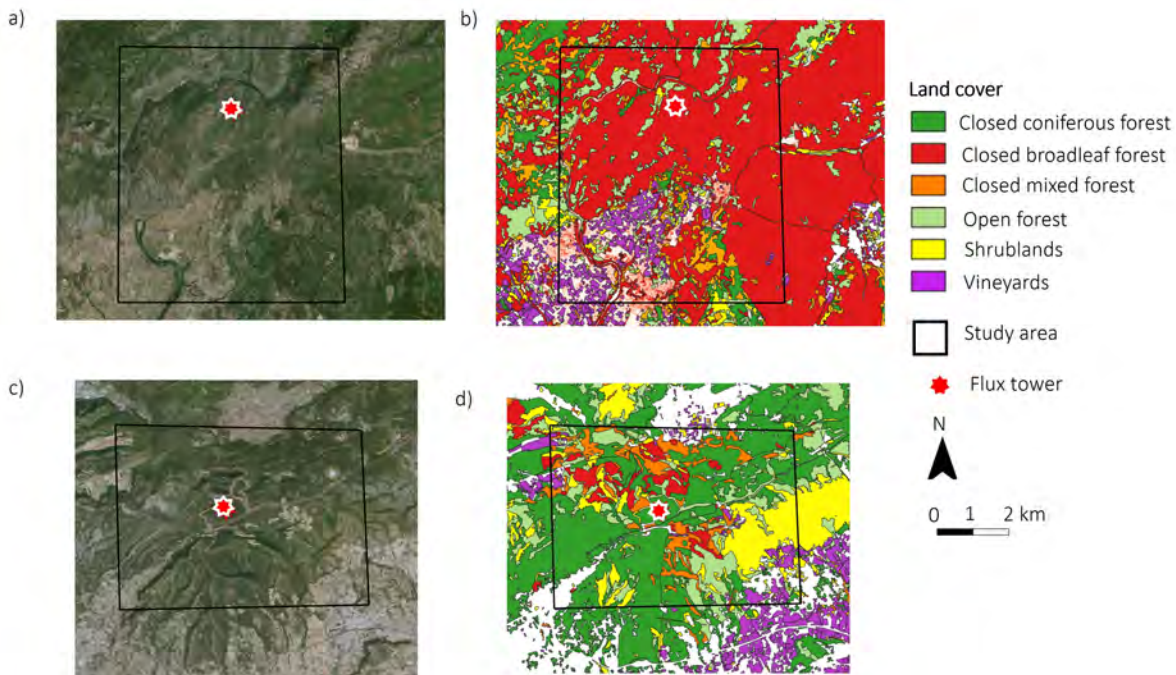


Figure 3: Extent of the study areas with background 2023 Spot images (left) and 2016 IGN land cover map (right) for Puechabon (top) and Fontblanche (bottom).

used to assess the impact of the uncertainty in the reanalysis data on the estimates of turbulent fluxes in the two study areas.

2.2. Satellite and airborne data set

2.2.1. Optical/thermal data

Landsat-7 Enhanced Thematic Mapper and Landsat-8/9 Operational Land Imager and Thermal Infrared Sensor provide reflectance and *LST* data with a 16-day revisit period, with an 8-day shift between Landsat-7/9 and Landsat-8. Landsat data for Path/Row 197/030 (Puechabon), 196/030 and 195/030 (Fontblanche) were downloaded from USGS Earth Explorer platform/Landsat Collection 2 Level-2 Science Products from 2014 to 2022 (Puechabon) and from 2013 to 2021 (Fontblanche).

Shortwave optical data are provided as bottom of atmosphere reflectances at their native resolution of 30 m. Landsat-7 data were processed with the Landsat Ecosystem Disturbance Adaptive

1
2
3
4 269 Processing System (LEDAPS) algorithm (Version 3.4.0) (Schmidt et al., 2013) and Landsat-8/9
5 270 data with the Land Surface Reflectance Code (LaSRC) algorithm (Version 1.5.0) (Vermote et al.,
6
7 271 2016).

8
9 272 f_{vg} is estimated using the expression of Carlson and Ripley (1997) :

$$f_{vg} = \left(\frac{NDVI - NDVI_{min}}{NDVI_{max} - NDVI_{min}} \right)^2 \quad (4)$$

10
11
12
13
14 273 with $NDVI$ being the Normalized Difference Vegetation Index defined as the difference of
15
16 274 near-infrared (NIR) and red (Red) reflectances divided by their sum. $NDVI_{min}$ (bare soil) and
17
18 275 $NDVI_{max}$ (full green cover) are set to 0.19 (0.24) and 0.86 (0.83) for Puechabon (Fontblanche),
19
20 276 respectively. Endmembers correspond to the quantile 0.01 and 0.97 of $NDVI$ values within the
21
22 277 study area and during the study period, as in Penot and Merlin (2023).

23
24 278 Landsat-7 and Landsat-8/9 LST data sets are processed with the Landsat surface temperature
25
26 279 algorithm to procure LST maps from raw thermal radiances (Cook et al., 2014; Cook, 2014). They
27
28 280 are provided over the same 30-m resolution grid of Landsat reflectances. Since the actual spatial
29
30 281 resolution of Landsat LST is close to 100 m, all Landsat-derived variables (LST , NIR and Red
31
32 282 before f_{vg} calculation) are aggregated to 90 m resolution using a 3x3 pixel moving window (90x90
33
34 283 m).

35 36 284 2.2.2. Airborne LiDAR data

37
38 285 A high-resolution airborne laser scanning (ALS) campaign led by the IGN started in 2021 and
39
40 286 will end in 2025. LiDAR point clouds, which are publicly available, were downloaded from the
41
42 287 IGN platform (IGN, 2024). The point clouds are provided already classified by IGN, and classes
43
44 288 corresponding to ground and vegetation are used. For pre-processing LiDAR data, we followed
45
46 289 the steps provided by (Martin-Ducup et al., 2025) who used the same data set to derive hc : (1)
47
48 290 point clouds filtering to keep ground and vegetation points and a statistical outlier removal filter
49
50 291 (filter parameters were $k = 5$ and $m = 10$) and (2) height normalization using a spatial interpolation
51
52 292 algorithm (with k and m parameters of 5 and 10 respectively) based on Delaunay triangulation over
53
54 293 points classified as ground category. Finally, we rasterized the quantile 0.90 of the normalized hc
55
56 294 to filter outliers at the Landsat spatial resolution of 90 m. All the above steps were computed with
57
58 295 the R package `lidr` (Roussel et al., 2020).

1
2
3
4 296 Figure 4 shows the hc over the study areas including the EC sites. In addition, the density plot
5
6 297 for hc is also provided for both sites. The LIDAR-derived hc at the EC-site-centred pixel (90 m
7
8 298 resolution) is 5.0 m and 12.1 m for Puechabon and Fontblanche, respectively. These values are
9
10 299 near the dominant tree values of the EC sites (5.5 m and 13 m for Puechabon and Fontblanche
11
12 300 respectively (Ollivier et al., 2021)). The slight underestimation could be due to the fact that we
13
14 301 use the 0.90 quantile of the normalised hc in the point clouds, but also to the subpixel variability
15
16 302 of hc at the 90-m scale.

17 303 Both study areas show very different patterns of hc . The great majority of hc values is near 5.0
18
19 304 m in the Puechabon study area and very few pixels have hc values larger than 10 m (see Figure 4
20
21 305 (b)). This is consistent with a land cover of olm oaks that commonly reach 5 m height. The highest
22
23 306 hc values are encountered along the Hérault river where riparian trees are present (see Figure 4
24
25 307 (a)). On the contrary, the hc values in the Fontblanche study area are more heterogeneous, with
26
27 308 the vast majority of hc values ranging from 2 to 15 m (see Figure 4 (d)). This is also consistent
28
29 309 with the different tree species that grow in this area (Olm oaks and Aleppo pines), which may be
30
31 310 mixed.

32 33 311 2.2.3. Date selection

34
35 312 The methodology used in Penot and Merlin (2023) to select the Landsat overpass dates is
36
37 313 followed. First, we select the hottest period of the year, that is from April to October from 2014 to
38
39 314 August 2022 (Puechabon) and from 2013 to 2021 (Fontblanche) so that LST is in moisture-driven
40
41 315 conditions at the surface rather than in energy-driven conditions (Chirouze et al., 2014; Karnieli
42
43 316 et al., 2010). Next, a threshold of 75% of clear pixels (according to the quality assessment flag of
44
45 317 Landsat-7/8/9) within the study area is chosen to filter out cloudy conditions and get representative
46
47 318 conditions within the study area. Finally, for each date when the minimum value of LST (within
48
49 319 the study area for the pixels qualified as clear by the Landsat-7/8/9 quality flag) is significantly
50
51 320 lower than air temperature (a threshold is set to the measured air temperature minus 5 K), the
52
53 321 image is considered as contaminated by clouds and is hence removed from the dataset (Zhang
54
55 322 et al., 2014).

56 323 In addition, after 2017 Landsat-7 has an earlier overpass time than before 2017. Although,

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
324
33
34
325
35
36
326
37
38
39
327
40
41
328
42
43
329
44
45
330
46
47
331
48
49
332
50
51
333
52
53
334
54
55
335
56
57
58
59
60
61
62
63
64
65

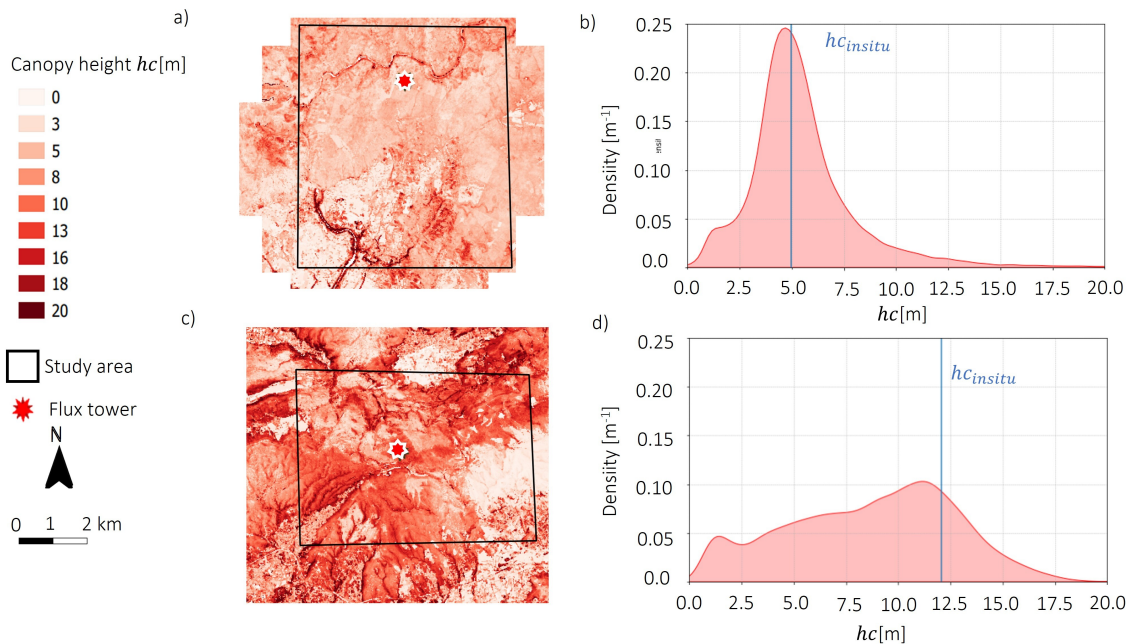


Figure 4: hc maps (left) and hc density histogram (right) over Puechabon (top) and Fontblanche (bottom) study area.

changes in reflectance and thermal data had been limited until 2020 (Qiu et al., 2021), we chose to keep only Landsat-7 acquisitions after 10:00 a.m. and before 2020 (2020 included) in the data set, for consistency between Landsat-7 and Landsat-8/9 data.

2.3. Classical contextual method

2.3.1. Estimating EF

The classical contextual method based on the $LST-f_{vg}$ space (Carlson, 2020; Jiang and Islam, 1999; Moran et al., 1994; Tang et al., 2010; Venturini et al., 2004) is used. Figure 5 (a) plots the $LST-f_{vg}$ feature space on the 26th, April 2019 over the Fontblanche study area. The $LST-f_{vg}$ space is bounded by a linear upper edge, called "dry edge", and a linear lower edge, called "wet edge". These linear boundaries define the extreme moisture values, from $EF = 0$ for a point on the dry edge, to $EF = 1$ for a point on the wet edge. Particularly, the endmembers of the dry edge are called Tsd ($f_{vg} = 0$) and Tvd ($f_{vg} = 1$) for dry soil and vegetation temperature, respectively. For an observed point C in the $LST-f_{vg}$ space, EF is estimated as the ratio of the distance between the

1
2
3
4 337 point C and the point A of same f_{vg} on the dry edge, and the distance between the point A and the
5
6 338 point B of same f_{vg} on the wet edge (Merlin, 2013; Moran et al., 1994; Penot and Merlin, 2023).
7
8 339 Thus, this method allows to take into account the impact of vegetation cover on LST -derived EF .
9
10 340 This value of EF , derived from the classical method (" $LST - f_{vg}$ ") is used as a benchmark in this
11
12 341 study.

13 342 One of the challenge using this method, is to estimate the dry and wet edges (Long and Singh,
14
15 343 2012; Long et al., 2012; Stisen et al., 2008; Sun et al., 2017; Tang et al., 2010)over areas and on
16
17 344 dates when such extreme conditions are not met at the spatial resolution of the satellite sensor.

20 345 2.3.2. *Estimating the wet edge in the Mediterranean context*

21
22 346 As wet conditions are rare in the Mediterranean context between April and October, low LST
23
24 347 values are generally misleading if interpreted as representative of wet conditions. Therefore, in
25
26 348 this study the wet edge is set to the T_{air} (see Figure 5 (a)) at the Landsat overpass time (around
27
28 349 10:30 am), by assuming that LST in wet conditions is close to T_{air} . Such an assumption has been
29
30 350 made by many other studies conducted in (semi-arid) environments (Amazirh et al., 2018; Long
31
32 351 and Singh, 2012; Long et al., 2012; Merlin, 2013; Sun et al., 2017; Zhang et al., 2014), including
33
34 352 the Puechabon area (Penot and Merlin, 2023).

36 353 2.3.3. *Estimating the dry edge*

37
38 354 Since the Mediterranean region has generally dry conditions during late spring, summer and
39
40 355 early autumn, we assume, as a first guess, that dry conditions are present at Landsat resolution
41
42 356 within the study areas. Therefore, a statistical technique for estimating the dry edge is used. The
43
44 357 dry edge is defined as the linear regression of the 99% quantiles of LST evaluated in equal-length
45
46 358 f_{vg} bins against f_{vg} as in Penot and Merlin (2023); Virlet et al. (2014) (see Figure 5 (a)).

49 359 2.4. *New contextual method by integrating hc*

50
51 360 In this Section the interpretation of the new $LST-hc$ feature space is first presented (Section
52
53 361 2.4.1), then the estimation of the decreasing rate of LST with hc is displayed (Section 2.4.2)
54
55 362 and LST is normalized for the hc effects (Section 2.4.3). Finally EF is estimated from the new
56
57 363 $LST_{norm-f_{vg}}$ space (Section 2.4.4).

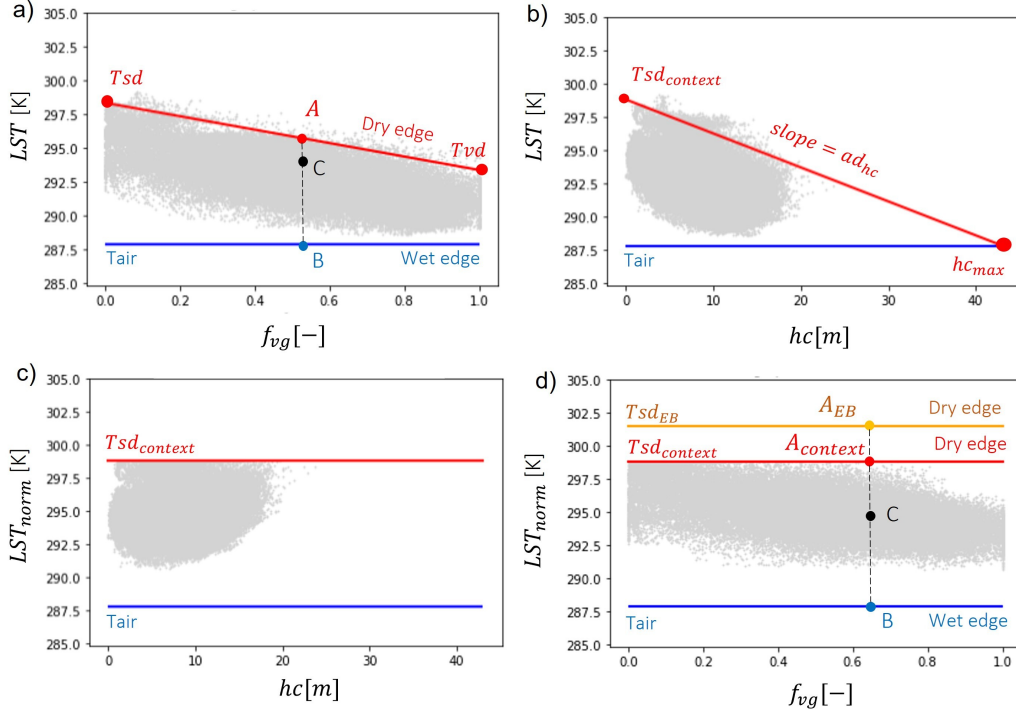


Figure 5: Feature spaces for data collected over the Fontblanche study area on the 26th, April 2019 : a) classical $LST-f_{vg}$ space, b) new $LST-hc$ space, c) new $LST_{norm}-hc$ space and d) new $LST_{norm}-f_{vg}$ space. For each space the contextual upper/dry edge is plotted in red and the lower/wet edge in blue.

2.4.1. Interpreting the new $LST-hc$ feature space

Figure 5 (b) plots LST versus hc , hereafter called $LST-hc$ space, over the Fontblanche study area on the 26th, April 2019. In this space, the point cloud is apparently bounded at the top by a linearly decreasing upper edge (red), which is remarkably visible and well-defined. This illustrates the decrease of LST with increasing hc , called "hc effect". The slope of this linear upper edge, ad_{hc} , quantifies the decrease rate of LST with hc . On this upper edge the EF is near 0, i.e., H is the main way to dissipate turbulent energy. This is consistent with the physical understanding of the impact of hc on LST , through the parametrization of roughness parameters from hc estimates in many EB models (Boulet et al., 2015; Choudhury et al., 1986; Sun et al., 2017; Trebs et al.,

2021), which explicitly quantify the decrease of LST with hc for given meteorological conditions.

The intersection between the dry edge and the wet edge (set to T_{air}) corresponds to the value of hc – called hc_{max} – for which $LST = T_{air}$. From a physical point of view, $LST = T_{air}$ at $hc = hc_{max}$ means no convection ($H = 0$) on both wet and dry edges, while on the dry edge all the available energy is dissipated by H . Consequently, hc_{max} is the threshold value of hc above which LST is no longer coupled with turbulent fluxes. Herein we assume that the decreasing rate of LST with hc is uniform within the study area, and can therefore be estimated from the dry edge through the slope ad_{hc} . This assumption is consistent with the fact that hc is used as a proxy for aerodynamic roughness (or in roughness parameters), which does not depend on EF /hydraulic stress (Banerjee et al., 2017; Trebs et al., 2021).

2.4.2. Estimating the decreasing rate of LST with hc

The slope ad_{hc} and the intercept $Tsd_{context}$ of the dry edge are statistically calculated from the linear regression of the 99% quantiles of LST evaluated in equal-length hc bins against hc . The slope ad_{hc} quantifies the decrease rate of LST as a function of hc , while the intercept ($Tsd_{context}$) is used as a proxy for the maximum LST reached in the study area (both for dry bare soil and $hc = 0$ conditions) to avoid outliers. By extrapolating this upper edge, the hc at which LST is equal to T_{air} is hc_{max} (see Figure 5 (b)). The LST - hc feature space is interpreted similarly for all Landsat overpass dates during the study period and for each study area. We define Hc_{max} as the median of the daily hc_{max} . If Hc_{max} is calculated for both sites together, hereafter referred to as the All-Site dataset, Hc_{max} is the median of the All-Site hc_{max} . When Hc_{max} is calculated separately for each site, hereafter referred to as the Per-Site data set, Hc_{max} is the median of the Per-Site hc_{max} .

2.4.3. Normalizing LST for hc effect

The slope of the upper edge of the LST - hc feature space ad_{hc} is used to normalise LST for hc effect: If $LST > T_{air}$

$$LST_{norm} = LST + \frac{hc}{Hc_{max}} (Tsd_{context} - T_{air}) \quad (5)$$

else :

$$LST_{norm} = T_{air}$$

1
2
3
4 397 LST_{norm} is hence a conceptual LST , which would be equivalent to LST for hc tending towards
5
6 398 0. An illustration of such a normalization is provided in Figure 5 (c).

7 8 399 2.4.4. Estimating EF from the new $LST_{norm}-f_{vg}$ space

10 400 LST_{norm} is the equivalent of LST for a zero hc . Therefore, the normalized Tsd is equal to
11
12 401 Tsd (normalization is zero for $hc = 0$) and the normalized Tvd is close to Tsd . As a matter of
13
14 402 fact, the dry edge of the new $LST_{norm}-f_{vg}$ space is assumed to be flat, similarly to the wet edge
15
16 403 for the classical contextual method. Note that this is consistent with the concept that hc is a good
17
18 404 proxy for roughness, via aerodynamic resistance (Banerjee et al., 2017; Tian et al., 2011; Trebs
19
20 405 et al., 2021), explaining the negative slope of the dry edge in the classical $LST-f_{vg}$ space as surface
21
22 406 roughness is generally much smaller for bare soil than for full cover vegetation (Sun et al., 2017).

23
24 407 Two different approaches are considered to determine Tsd in the new $LST_{norm}-f_{vg}$ space.
25
26 408 $LST_{norm} - f_{vg}(Tsd_{context})$ corresponds to a dry edge ($Tsd_{context}$) determined statistically as in Section
27
28 409 2.4.2 (see Figure 5 (d)). $LST_{norm} - f_{vg}(Tsd_{EB})$ corresponds to Tsd_{EB} , which is modelled using a
29
30 410 simple soil EB model (see Appendix A and Figure 5 (d)) fed with meteorological data as input.
31
32 411 Note that $LST_{norm} - f_{vg}(Tsd_{EB})$ is proposed as a solution for the dry edge (Long et al., 2012) to
33
34 412 compensate for probable errors of the $LST_{norm} - f_{vg}(Tsd_{context})$ approach on Landsat overpass dates
35
36 413 occurring right after rain events. In fact, the statistically-derived $Tsd_{context}$ is likely to be under-
37
38 414 estimated in such conditions when the requirement of dry conditions is not observed within the
39
40 415 study area (Stisen et al., 2008). In $LST_{norm} - f_{vg}(Tsd_{context})$ (resp. $LST_{norm} - f_{vg}(Tsd_{EB})$), EF is
41
42 416 evaluated in the $LST_{norm}-f_{vg}$ space as described in Section 2.3.1 (see illustration in Figure 5 (d)).

43 44 417 2.5. Estimating H and LE turbulent fluxes

45
46 418 For both classical and new contextual approaches, the satellite-derived turbulent fluxes are
47
48 419 estimated as:

$$49 \quad H = (1 - EF) Rn_{mod} \quad (6)$$

$$50 \quad LE = EF \times Rn_{mod} \quad (7)$$

with the EF derived from the $LST - f_{vg}/LST_{norm} - f_{vg}(Tsd_{context})/LST_{norm} - f_{vg}(Tsd_{EB})$ approach and Rn_{mod} as:

$$Rn_{mod} = (1 - \alpha)Rg + \epsilon_s R_a - \epsilon_s \sigma LST^4 \quad (8)$$

Where α is the satellite-derived albedo [-], $\epsilon_s=0.97$, the surface emissivity [-], R_a the downward atmospheric longwave radiation [$W.m^{-2}$] and σ , the Stefan-Boltzmann constant [$W.m^{-2}.K^{-4}$]. For details on the evaluation of R_a , see Appendix A. α is estimated with the expression of Courault et al. (2008) and used in Chirouze et al. (2014); Merlin (2013):

$$\alpha = 0.645Red + 0.382NIR \quad (9)$$

2.6. Sensitivity analysis to input data

Both the normalisation of LST for hc effect and the use of an EB model to estimate Tsd require parameters or input data. As these parameters and input data are uncertain, a method to assess the sensitivity of H and LE estimates to these factors is proposed.

2.6.1. Sensitivity analysis to Hc_{max}

To assess the sensitivity of the turbulent fluxes estimates to uncertainties in Hc_{max} , we take the All-Site or Per-Site values of Hc_{max} for the normalization of LST . We then compare the performance metrics of the estimates between the two values of Hc_{max} .

2.6.2. Sensitivity analysis to meteorological data

$Tair$, Rg and RH are needed in all methods ($LST - f_{vg}$, $LST_{norm} - f_{vg}(Tsd_{context})$ and $LST_{norm} - f_{vg}(Tsd_{EB})$). $Tair$ is used to set the wet edge. Rg and RH are used to compute Rn_{mod} . WS is also needed in $LST_{norm} - f_{vg}(Tsd_{EB})$ in addition to the other parameters to estimate Tsd_{EB} . Meteorological data are initially provided by in situ measurements (see Section 2.1.4). To assess the impact of uncertainties in meteorological data to H and LE estimates in the $LST_{norm} - f_{vg}(Tsd_{EB})$ approach, which is assumed to be the most sensitive approach to meteorological data uncertainty, SAFRAN reanalysis data (see Section 2.1.4) are used as input data. We then compare the performance metrics of the turbulent heat flux and EF estimates between the two meteorological data sets.

2.6.3. Sensitivity analysis to the ground heat flux to Rn ratio

In $LST_{norm} - f_{vg}(Tsd_{EB})$ approach, the dry edge is set at the maximum soil temperature (for $EF = 0$) simulated by a EB model, assuming that 1) the difference in radiative properties (emissivity and albedo) between soil and vegetation components are second-order effects on the LST relative to hc effects and 2) the ground heat flux (G) is equal to its value in the bare ground throughout the f_{vg} range. In this study, no sensitivity analysis is performed on radiative properties, since the difference in albedo between soil and vegetation is small (albedo=0.20/0.19 and albedo=0.15/0.14 for soil/vegetation for the Puechabon and Fontblanche EC sites respectively (Napoly, 2016; Napoly et al., 2017) and emissivity is assumed to be equal to 0.97 for soil and vegetation (An et al., 2017). Consequently, neglecting the difference in radiative properties for soil and vegetation is deemed acceptable. However, the ratio of G to Rn called Cg , which represents the amount of available energy conducted through the soil, differs significantly between bare soil and vegetated surfaces (Kustas and Daughtry, 1990). It is commonly assumed that Cg decreases linearly with f_{vg} , from 0.32 for $f_{vg} = 0$ to 0 for $f_{vg} = 1$ (Purdy et al., 2016). A sensitivity analysis on $LST_{norm} - f_{vg}(Tsd_{EB})$ fluxes and EF estimates is hence conducted to assess the impact of Cg . In practice, Tsd_{EB} is simulated for two values of Cg , 0 and 0.32 (see Appendix A), and the impact on the performance metrics of the All-Site estimates of H and LE versus in situ H and LE is evaluated.

3. Results and discussion

First, the decreasing rate of LST with hc is quantified and LST is normalized for hc effect (Section 3.1). Then, results of $LST - f_{vg}$, $LST_{norm} - f_{vg}(Tsd_{context})$ and $LST_{norm} - f_{vg}(Tsd_{EB})$ in terms of H , LE and EF estimates are presented and discussed (Section 3.2). Finally, the results of the sensitivity analysis of the methods to uncertainties in input data are provided in Section 3.3.

3.1. Decreasing rate of LST with hc

Figures 6 and 7 show the $LST-hc$ spaces on 14 randomly selected dates (2 per month) for the Puechabon and Fontblanche study areas respectively. Whatever the date and study area, the linear upper edge of the $LST-hc$ space is remarkably well identified and is systematically decreasing. Furthermore, whatever the difference between $Tsd_{context}$ and T_{air} , the upper edge intersects the

1
2
3
4 471 lower edge ($LST = T_{air}$) at fairly stable hc_{max} values, between 35 m and 62 m, particularly for
5 472 the Fontblanche study area. For the Puechabon study area, the value of hc_{max} appears to be more
6
7 473 variable and relatively larger than for the Fontblanche study area.
8

9 474 Figure 8 shows the boxplot of hc_{max} including data for 96 and 110 dates for Puechabon and
10 475 Fontblanche respectively. Whatever the site, hc_{max} is positive and bounded (between 24 m and
11 476 137 m), illustrating the decreasing rate of LST with hc . The decrease of LST with hc can be
12 477 represented by an EB model, but few studies have quantified it by directly comparing LST values
13 478 for a wide range of hc . On an annual and spatial average in the contiguous United States, (Zhang
14 479 et al., 2022) showed that LST decreases with hc , regardless of forest type (evergreen, deciduous
15 480 or mixed). Similarly, (Shaik et al., 2023) has shown that in Sardinia, on a monthly scale (October
16 481 2021 average), MODIS LST is also a decreasing function of hc . In that study, the slope of the
17 482 linear regression of LST versus hc was estimated per land cover as (mean [+/- standard deviation])
18 483 -0.47 [+/-0.13] $K.m^{-1}$. These values are relatively consistent with ours ($ad_{hc} = 0.39$ [+/- 0.13]
19 484 $K.m^{-1}$).
20
21
22
23
24
25
26
27
28
29

30 485 The Per-Site hc_{max} and its daily variability slightly differ between the two study areas: Hc_{max}
31 486 $= 50$ m and $Hc_{max} = 39$ m, and the interquartile range is 22 m and 13 m for Puechabon and Font-
32 487 blanche respectively. These differences in variability and centrality may be due to the different
33 488 values of hc between the two study areas. In fact, the Fontblanche study area has a greater range
34 489 of hc values and hc is more evenly distributed between its minimum and maximum values than for
35 490 the Puechabon study area (see Figure 4). Consequently, the estimation method of the upper edge
36 491 of the $LST-hc$ for the Fontblanche study area is expected to be more robust than for the Puechabon
37 492 study area.
38
39
40
41
42
43
44
45
46

47 493 3.2. Estimating turbulent heat fluxes

48 494 In this section, a qualitative analysis of the LST , LST_{norm} , hc and EF maps derived on a spe-
49 495 cific Landsat overpass date over the Fontblanche study area is presented (Section 3.2.1). Following
50 496 this, quantitative results for the All-Site and Per-Site datasets in terms of turbulent heat flux and
51 497 EF estimates are presented and discussed for the $LST - f_{vg}$ and $LST_{norm} - f_{vg}(Tsd_{context})$ methods
52 498 (Section 3.2.2) and for the $LST_{norm} - f_{vg}(Tsd_{EB})$ method (Section 3.2.3).
53
54
55
56
57
58
59
60
61
62
63
64
65

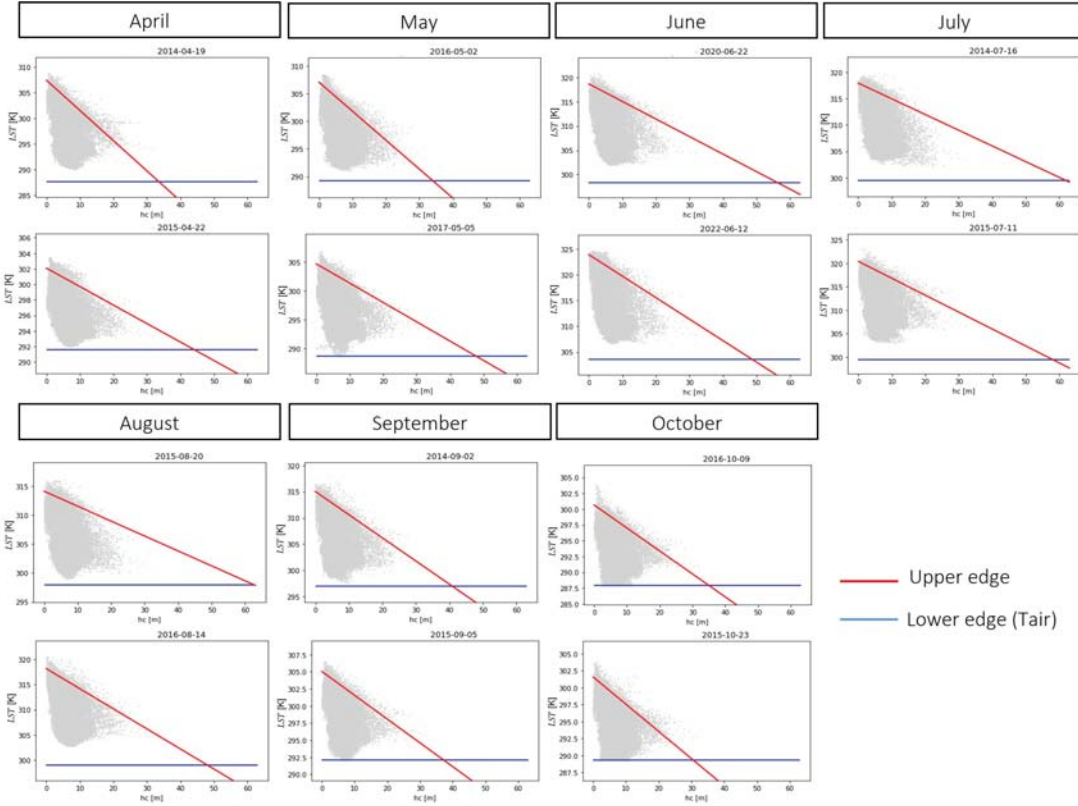


Figure 6: $LST-hc$ spaces for the Puechabon study area for data on 2 selected dates per month during the study period.

3.2.1. Qualitative analysis on a particular date

Figure 9 presents maps of LST (a) and LST_{norm} (b) over the Fontblanche study area using Landsat data on the 26th, April 2019. As expected, LST_{norm} is larger than LST across all locations, particularly in forested areas (see Figures 3 (c) and (d)), where hc values are relatively larger (see Figure 4 (c)). Figure 9 also displays maps of EF derived from the $LST - f_{vg} EF$ (c), $LST_{norm} - f_{vg}(Tsd_{context}) EF$ (d), and $LST_{norm} - f_{vg}(Tsd_{EB}) EF$ (e) methods.

The satellite-derived EF decreases globally across the entire area with the $LST_{norm} - f_{vg}(Tsd_{context})$ approach compared to the baseline approach. The range of $LST_{norm} - f_{vg}(Tsd_{context}) EF$ values is smaller than that of the $LST - f_{vg} EF$, which aligns with the normalization of the hc effect. Between the two approaches, EF does not change significantly in areas where hc and $LST - f_{vg} EF$ are low. The main differences between the two methods lie in areas where LST_{norm} increases

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

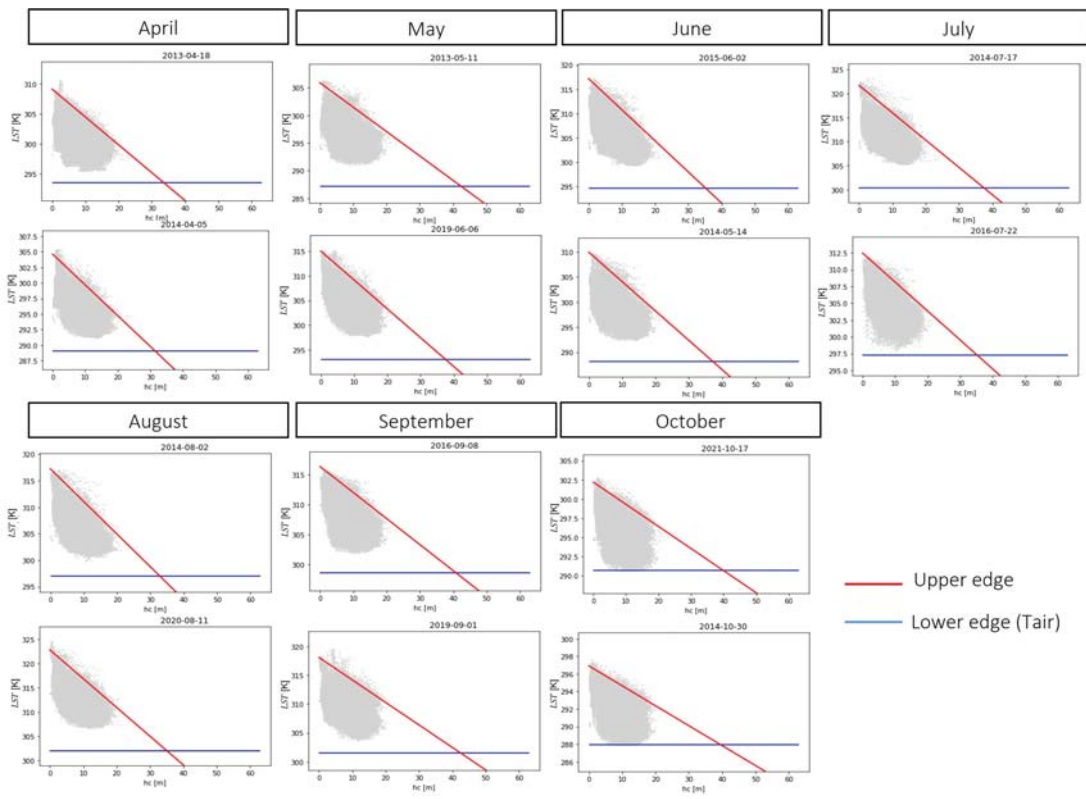


Figure 7: $LST-hc$ spaces for the Fontblanche study area for 2 selected dates per month during the study period.




Figure 8: Boxplot of hc_{max} for Puechabon (96 dates) and Fontblanche (110 dates) study areas.

relative to LST , especially in the southwest of the area. The $LST_{norm} - f_{vg}(Tsd_{EB}) EF$ increases uniformly across the study area compared to the $LST_{norm} - f_{vg}(Tsd_{context}) EF$.

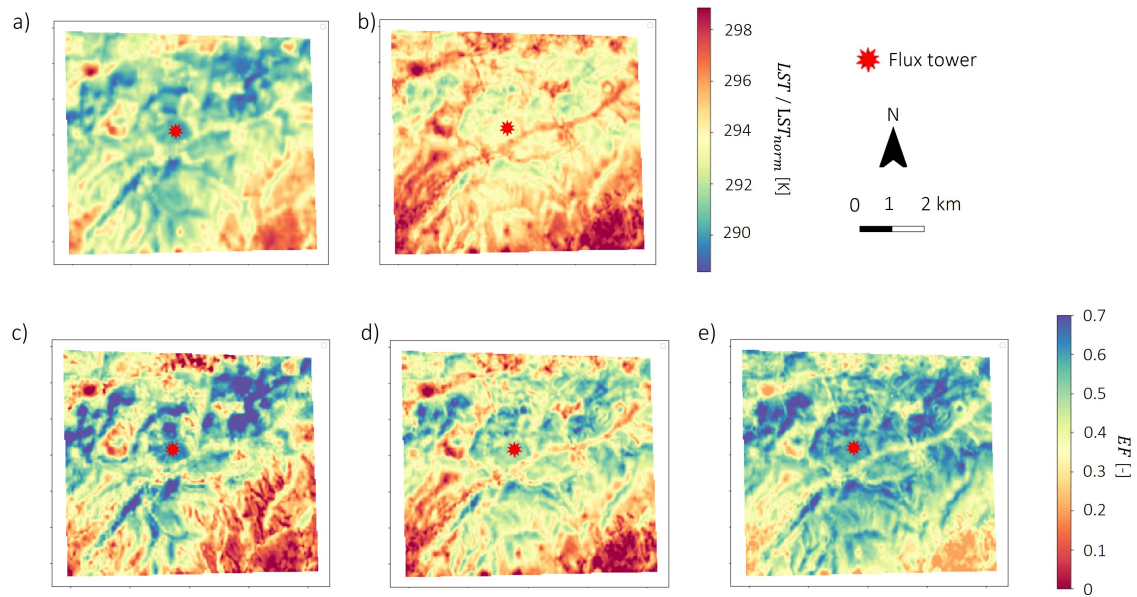


Figure 9: Maps over the Fontblanche study area on the 26th, April 2019 of : a) LST , b) LST_{norm} , c) $LST - f_{vg} EF$, d) $LST_{norm} - f_{vg}(Tsd_{context}) EF$, e) $LST_{norm} - f_{vg}(Tsd_{EB}) EF$.

3.2.2. $LST - f_{vg}$ and $LST_{norm} - f_{vg}(Tsd_{context})$ results and discussion

Figure 10 shows the scatter plots of satellite-based H , LE and EF ($LST - f_{vg}$ (a) and $LST_{norm} - f_{vg}(Tsd_{context})$ (b)) versus in situ measurements of H , LE and EF for the All-Site dataset ($H_{c_{max}}$ is set to 43 m). Overall, the H , LE and EF satellite-derived estimates show poor visual agreement with in situ measurements. The $LST - f_{vg} H$ underestimates the in situ H and consequently the $LST - f_{vg} LE$ and EF overestimates the in situ LE and EF , respectively. Furthermore, there is no obvious linear relationship between satellite-derived estimates and in situ measurements. Irrespective of the flux, the groups of scatter points corresponding to each EC site are separated. On the contrary, $LST_{norm} - f_{vg}(Tsd_{context})$ estimates of H , LE and EF show better visual agreement with in situ measurements. Although there is still an underestimation of high H values and an overestimation of low LE/EF values, a linear relationship between estimated and measured H , LE and EF is visually apparent. Furthermore, the satellite-derived estimates of H , LE and EF for the two EC sites appear to have the same error trend (bias and slope) because their point clouds are almost superimposed.

Variables	Performance metrics	$LST - f_{vg}$	$LST_{norm} - f_{vg}(Tsd_{context})$	$LST_{norm} - f_{vg}(Tsd_{EB})$	$LST_{norm} - f_{vg}(Tsd_{EB})$
		in situ meteo	in situ meteo	in situ meteo	SAFRAN meteo
H	$RMSE$ [$W.m^{-2}$]	197	180	100	133
	bias [$W.m^{-2}$]	-162	-161	-30	-94
	R	0.39	0.72	0.71	0.67
	slope	0.28	0.45	0.81	0.67
LE	$RMSE$ [$W.m^{-2}$]	175	153	105	124
	bias [$W.m^{-2}$]	132	130	-1	70
	R	0.06	0.36	0.41	0.41
	slope	0.06	0.23	0.53	0.51
EF	$RMSE$	0.31	0.28	0.18	0.22
	bias	0.24	0.25	0.01	0.13
	R	0.02	0.36	0.45	0.41
	slope	0.02	0.21	0.61	0.52

Table 1: Root mean square error ($RMSE$), bias, correlation (R) and slope of the linear regression between satellite-derived and in situ H , LE and EF for the All-Site dataset and Hc_{max} set to 43 m.

From a quantitative point of view, it is important to note that the modelling of Rn (Rn_{mod}) is quite accurate when compared to in situ measurements, with an R of 0.98 and a slope of the linear regression of 0.90. Table 1 reports the performance metrics (R , $RMSE$, slope and bias) in terms of satellite-derived H , LE and EF versus in situ H , LE and EF . The $LST - f_{vg}$ approach underestimates (overestimates) high (low) values of H (LE) with low $R = 0.39(0.06)$ and a strong negative (positive) bias = -162(132) $W.m^{-2}$. It also overestimates EF with a bias of 0.24 without providing any correlation ($R = 0.02$). On the contrary, the normalization of LST for hc effect ($LST_{norm} - f_{vg}(Tsd_{context})$) greatly improves the satellite-derived estimations of EF and fluxes. More specifically, the correlation is increased for H , LE ($R = 0.72$ and $R = 0.36$ respectively) and EF ($R = 0.36$). Despite this improvement, H is still significantly underestimated (bias = -161 $W.m^{-2}$) especially for large H values (slope = 0.45) and LE is overestimated (bias = 130 $W.m^{-2}$) especially for small LE values (slope = 0.23), since EF remains overestimated (bias = 0.25).

The same analysis is made for each site separately. For $LST_{norm} - f_{vg}(Tsd_{context})$, Hc_{max} is now set to the value obtained at the site level, i.e. 50 m and 39 m for Puechabon and Fontblanche respectively. Figures 11 and 12 compare satellite-derived versus in situ H , LE and EF for the $LST - f_{vg}$ (a) and $LST_{norm} - f_{vg}(Tsd_{context})$ (b) approaches and for Puechabon and Fontblanche EC

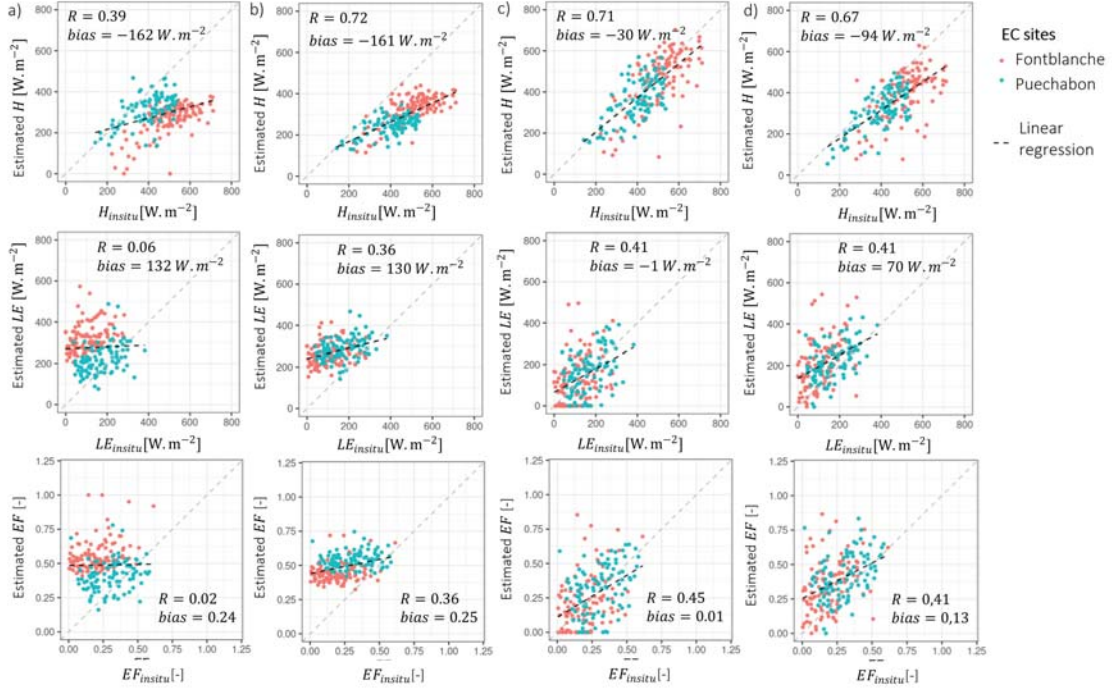


Figure 10: Scatter plot of satellite versus in situ $H/LE/EF$ for the All-Site data set (H_{cmax} set to 43 m), using the $LST - f_{vg}$ method and in situ meteo data (a), $LST_{norm} - f_{vg}(Tsd_{context})$ method and in situ meteo data (b), $LST_{norm} - f_{vg}(Tsd_{EB})$ method and in situ meteo data (c) and $LST_{norm} - f_{vg}(Tsd_{EB})$ method and SAFRAN meteo data (d).

site separately. The $LST - f_{vg}$ results differ between the two EC sites when considered separately. In fact, the $LST - f_{vg}$ estimates of H , LE and EF for the Puechabon EC site do not show such a significant underestimation (H) or overestimation (LE and EF) as in the Fontblanche EC site. Overall, there is no clear relationship between satellite-derived EF/LE and in situ EF/LE at both EC sites, but such a relationship exists between satellite-derived and in situ H . The $LST_{norm} - f_{vg}(Tsd_{context})$ approach reduces the absolute bias by almost a third in the Fontblanche EC site for H , LE and EF while retaining the correlation for H . However, the $LST_{norm} - f_{vg}(Tsd_{context})$ approach does not improve the satellite-derived estimates of H , LE and EF at the Puechabon EC site, as the underestimation (overestimation) for H (LE and EF) is increased and the slope of the linear regression is not closer to 1.

Table 2 presents the performance metrics of the $LST - f_{vg}$ and $LST_{norm} - f_{vg}(Tsd_{context})$ ap-

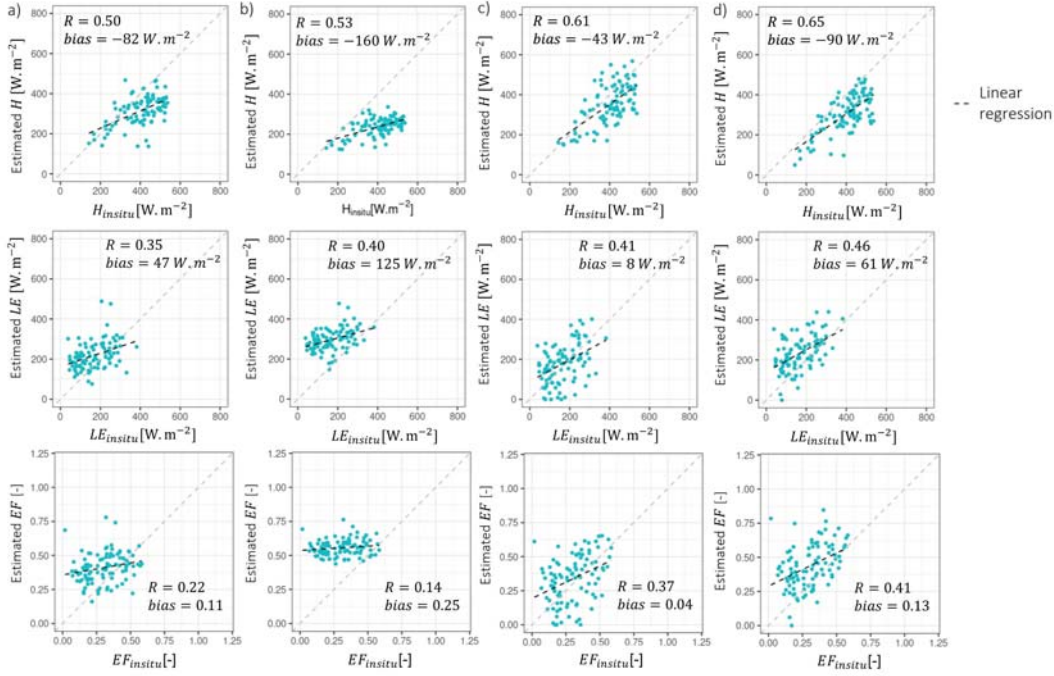


Figure 11: Same as Figure 10 but for Per-Site data set of Puechabon ($H_{C_{max}}$ set to 50 m).

proaches in terms of H , LE and EF for the Per-site data sets separately. Using the $LST - f_{vg}$ approach, H and LE are relatively well estimated for Puechabon site (bias=-82/47 W.m⁻² and $R = 0.50/0.35$ for H/LE). On the contrary, at the Fontblanche EC site, H is clearly underestimated (bias=-233 W.m⁻²) and LE is clearly overestimated (bias=206 W.m⁻²), although they show a satisfactory correlation ($R = 0.70/0.33$ for H/LE). These results are consistent with performance metrics for EF . A notable result is that the $LST - f_{vg}$ approach overestimates EF for the Fontblanche EC site (bias = 0.36), while the positive bias is three times lower for the Puechabon EC site (bias=0.11). The correlation between satellite-derived EF ($LST - f_{vg}$) and in situ EF is slightly better for the Fontblanche EC site ($R = 0.35$) than for the Puechabon EC site ($R = 0.22$). The $LST_{norm} - f_{vg}(Tsd_{context})$ approach does not seem to bring any clear quantitative improvements to these performance metrics at the site level, since the bias of H (LE) is increased at Puechabon site – bias is -160 W.m⁻² (125 W.m⁻²) – although it is much reduced (but still significant) at Fontblanche site – the bias is -153 W.m⁻² (126 W.m⁻²).

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

EC site	Variables	Performance metrics	$LST - f_{vg}$	$LST_{norm} - f_{vg}(Tsd_{context})$	$LST_{norm} - f_{vg}(Tsd_{EB})$	$LST_{norm} - f_{vg}(Tsd_{EB})$
			in situ meteo	in situ meteo	in situ meteo	SAFRAN meteo
Puechabon	H	RMSE [$W.m^{-2}$]	118	178 [-8]*	97 [-4]*	119 [-8]*
		bias [$W.m^{-2}$]	-82	-160 [9]*	-43 [12]*	-90 [12]*
		R	0.50	0.53[0]*	0.61[0.01]*	0.65[0]*
		slope	0.40	0.26[0.01]*	0.67[0.02]*	0.66[0.02]*
	LE	RMSE [$W.m^{-2}$]	98	147 [-7]*	98 [0]*	106 [-6]*
		bias [$W.m^{-2}$]	47	125 [-9]*	8 [-12]*	61 [-12]*
		R	0.35	0.4 [0]*	0.41 [0]*	0.46 [0]*
		slope	0.3	0.27 [-0.01]*	0.48 [0]*	0.49 [0]*
	EF	RMSE	0.19	0.29 [-0.01]*	0.18 [0]*	0.21 [-0.01]*
		bias	0.11	0.25 [-0.02]*	0.04 [-0.02]*	0.13 [-0.02]*
		R	0.22	0.14 [0]*	0.37[0]*	0.41 [0]*
		slope	0.18	0.06 [0]*	0.48[0.01]*	0.49 [0.01]*
Fontblanche	H	RMSE [$W.m^{-2}$]	246	173 [16]*	102 [4]*	135 [14]*
		bias [$W.m^{-2}$]	-233	-153 [-17]*	-11 [-18]	-88 [-21]*
		R	0.7	0.69 [-0.01]*	0.68 [-0.01]*	0.62 [-0.01]*
		slope	0.5	0.44 [-0.02]*	0.82 [-0.02]*	0.68 [-0.03]*
	LE	RMSE [$W.m^{-2}$]	222	150 [15]*	111 [0]*	131 [11]*
		bias [$W.m^{-2}$]	206	126 [17]*	-17 [18]*	67 [21]*
		R	0.33	0.22 [0]*	0.33 [0.01]*	0.39 [0]*
		slope	0.29	0.15 [0.01]*	0.46 [0.03]*	0.59 [-0.01]*
	EF	RMSE	0.39	0.26 [0.03]*	0.18 [0]*	0.22 [0.02]*
		bias	0.36	0.22 [0.03]*	-0.02 [0.03]*	0.12 [0.04]*
		R	0.35	0.24 [0]*	0.39 [0.01]*	0.35 [0]*
		slope	0.31	0.13 [0]*	0.59 [0.02]*	0.53 [-0.02]*

Table 2: : RMSE, bias, R and slope of the linear regression between satellite-derived and in situ H, LE and EF for the Per-Site dataset and $H_{C_{max}}$ set to 50 m and 39 m for the Puechabon and Fontblanche EC sites respectively.

*In brackets is the difference between the performance metrics per site of the All-Site estimates and the performance metrics of the Per-Site estimates of H, LE and EF.

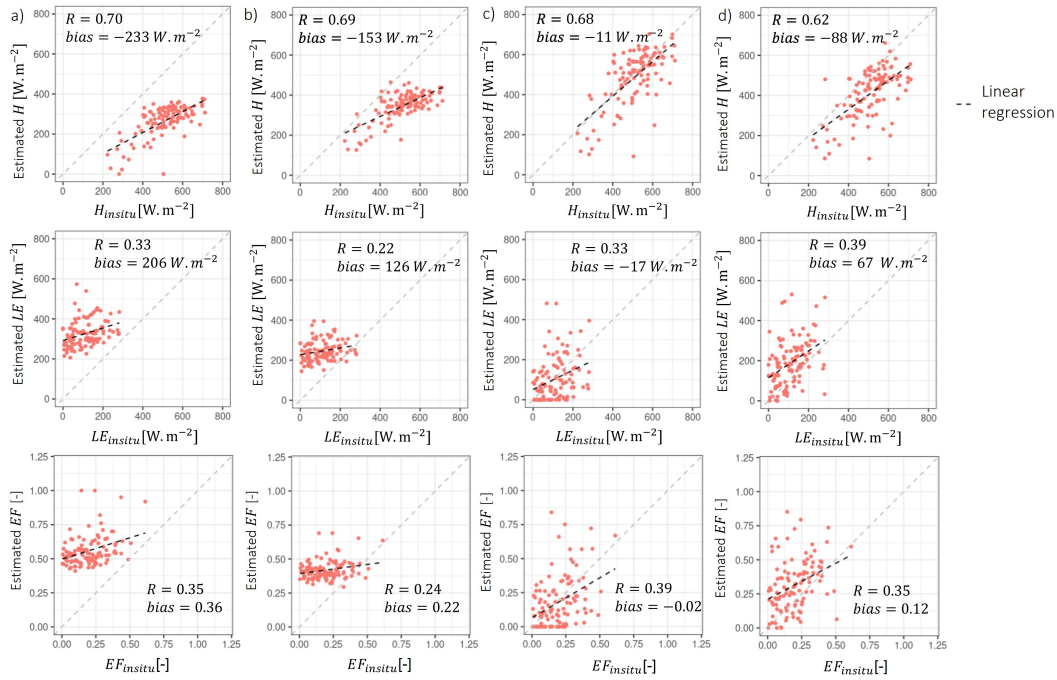


Figure 12: Same as Figure 10 but for Per-site data set of Fontblanche ($H_{C_{max}}$ set to 39 m).

566 The $LST - f_{vg}$ approach provides strongly biased estimates for H , LE and EF at the Font-
567 blanche EC site, whereas they are less biased at the Puechabon EC site. Since the climatic context
568 of the two sites is quite similar (see Figure 2), the origin of the difference between the two sites
569 could be the structure of the land cover (see Figure 4), which affects LST . One of the structural
570 differences that plays a role in the thermal behaviour of the surface is hc , as a proxy for surface
571 roughness. Indeed, the normalization of LST for hc effect ($LST_{norm} - f_{vg}(Tsd_{context})$) has a two-
572 side effects on the estimates of H , LE and EF . On the one hand, the estimates of EF are degraded
573 for Puechabon, while they are improved for Fontblanche ($R = 0.14/0.24$ and $bias = 0.25/0.22$ for
574 Fontblanche/Puechabon). This is also true for H and LE , which follow the same trend as for EF .
575 On the other hand, normalization for hc effect allows the satellite-derived H , LE and EF to show
576 almost the same trend of error (bias, slope and $RMS E$) for both EC sites simultaneously. Elim-
577 inating the effect of hc on LST reduces the biases on H/LE fluxes and on EF to a value common
578 to both EC sites. Both EC sites can therefore be treated as a homogeneous data set, rather than

1
2
3
4 579 as two different sites with their own structural characteristics. This is a remarkable result given
5
6 580 the difference in hc between the two sites ($hc_{insitu}=5.5/13$ m for Puechabon/Fontblanche). Nor-
7
8 581 malization for the hc effect is therefore a step forward. Indeed, unlike the EB modelling approach
9
10 582 for retrieving H , LE , and EF , which requires site-specific parameterizations, the use of LST_{norm} -
11
12 583 equivalent to LST for $hc = 0$ – offers a practical method for further improving the robustness of
13
14 584 contextual methods in a wide range of hc values. Nevertheless, LST normalization for the hc
15
16 585 effect in the $LST_{norm} - f_{vg}(Tsd_{context})$ approach is unable to effectively correct for persistent biases
17
18 586 in the mean and variance of satellite-derived H , LE and EF .

19 20 587 3.2.3. $LST_{norm} - f_{vg}(Tsd_{EB})$ results and discussion

21
22 588 Before applying the $LST_{norm} - f_{vg}(Tsd_{EB})$ approach to both study areas, the performance of
23
24 589 the EB model to simulate the maximum soil surface temperature (Tsd_{EB}) is qualitatively assessed
25
26 590 for the All-Site dataset. Stefan et al. (2015) underlined that the main factor that contributes to
27
28 591 the physically-based estimation of Tsd is the aerodynamic resistance, whose main parameter is
29
30 592 the momentum roughness height (z_{0m}). In our study, z_{0m} is set equal to 0.003 m, which is in the
31
32 593 range of well accepted values for soil (Allen et al., 2007; Liu et al., 2007; Nishida et al., 2003;
33
34 594 Yang et al., 2008). The graph in Figure 13 intercompares the simulated (Tsd_{EB}) and contextually-
35
36 595 derived ($Tsd_{context}$) Tsd . The correlation, bias and slope of the linear regression between Tsd_{EB}
37
38 596 and $Tsd_{context}$ is 0.92, -3.9 K and 0.68, respectively. The good correlation for both sites indicates
39
40 597 the robustness of the EB model to account for the temporal and spatial variability of meteorological
41
42 598 forcing. However, the general underestimation of Tsd by the EB model is counter-intuitive, given
43
44 599 that the purpose of using a model to estimate the dry edge is precisely to correct for a possible
45
46 600 underestimation of the contextually-derived dry edge in relatively wet conditions within the study
47
48 601 area. Apart from the negative bias on Tsd , the variability of Tsd_{EB} about $Tsd_{context}$ (the unbiased
49
50 602 $RMS E$ between Tsd_{EB} and $Tsd_{context}$ is estimated at 3.4 K) is expected to improve the sensitivity
51
52 603 of the satellite-derived EF in a wide range of meteorological conditions.

53 604 The EB model is now implemented in the $LST_{norm} - f_{vg}(Tsd_{EB})$ approach to force the dry edge
54
55 605 of the contextual method and the results in terms of H , LE and EF estimates are evaluated. The
56
57 606 All-Site estimates of H , LE and EF provided by $LST_{norm} - f_{vg}(Tsd_{EB})$ approach (see Figure 10 (c)




Figure 13: Scatter plot of Tsd_{EB} versus $Tsd_{context}$ for the All-Site dataset. In situ meteorological data are used as input to the EB model.

and Table 1) are greatly improved in comparison with the $LST - f_{vg}$ and the $LST_{norm} - f_{vg}(Tsd_{context})$ approaches. Especially, the $LST_{norm} - f_{vg}(Tsd_{EB})$ approach (see Figure 10 (c)) considerably reduces the underestimation of H (overestimation of LE/EF), while retaining the improved correlation provided by the $LST_{norm} - f_{vg}(Tsd_{context})$ approach compared with the $LST - f_{vg}$ approach. Indeed (see Table 1), the biases in satellite-derived H and LE are respectively -30 and -1 $W.m^{-2}$ and the slopes increase up to 0.81 and 0.53 while the correlations are $R = 0.71/0.41$ for H/LE respectively. These improvements stem from the correlation between All-Site EF estimates and in situ EF , which is increased to $R = 0.45$, while the bias is almost null at 0.01.

Similar results are achieved for the Per-Site estimates (see Figures 11 and 12 and Table 2). At both the Puechabon and Fontblanche EC sites, the primary outcome is a significant reduction in the bias for H and LE , reaching low absolute values of -43/-11 $W.m^{-2}$ (H) and 8/-17 $W.m^{-2}$ (LE) respectively. A similar trend is observed for EF , with the bias decreasing from 0.25/0.22 to 0.04/-0.02 (Puechabon / Fontblanche) between $LST_{norm} - f_{vg}(Tsd_{context})$ and $LST_{norm} - f_{vg}(Tsd_{EB})$. Additionally, the slopes of the linear regression for H (0.67/0.82 for Puechabon/Fontblanche), LE (0.48/0.46), and EF (0.48/0.59) are much closer to 1 in all cases, while the $RMS E$ is generally reduced.

1
 2
 3
 4 623 Results of $LST_{norm} - f_{vg}(Tsd_{EB})$ are placed in the context of past studies on the Puechabon site
 5 624 (to the authors' knowledge, no previous study has assessed LST -derived fluxes at the Fontblanche
 6
 7 625 EC site). Bartkowiak et al. (2024) evaluated TSEB model using Sentinel-3 LST data downscaled
 8
 9 626 to 100 m spatial resolution over several sites from 2017 to 2021. TSEB performed well on vine-
 10
 11 627 yards ($R = 0.93$, 1 site), grasslands ($R = 0.55$, 4 sites), but less effectively on forests ($R = 0.22$, 3
 12
 13 628 sites). Especially, the authors reported a negative correlation ($R = -0.18$) for LE estimates at the
 14
 15 629 Puechabon EC site. Njuki et al. (2023) evaluated SEBS model at the Puechabon EC site using
 16
 17 630 in situ LST and meteorological data at half-hourly time scale from 2010 to 2011. Results indi-
 18
 19 631 cated $R = 0.78/0.86$, $RMS E = 133/108 \text{ W.m}^{-2}$, and bias = $-44.76/-35 \text{ W.m}^{-2}$ for H/LE respectively.
 20
 21 632 Despite the satisfying performance for all the half-hourly data, a significant underestimation (up
 22
 23 633 to 50 %) of midday H values was still present particularly between April and October. Finally,
 24
 25 634 Penot and Merlin (2023) evaluated the $LST - f_{vg}$ contextual method over the Puechabon site using
 26
 27 635 Landsat data from 2015 to 2021 between May and September. They reported performance metrics
 28
 29 636 for EF of $R = 0.57$, slope = 0.50 , $RMS E = 0.12$ and bias = -0.02 . In conclusion, the results from
 30
 31 637 $LST_{norm} - f_{vg}(Tsd_{EB})$ clearly improve estimates of all turbulent fluxes and EF simultaneously at
 32
 33 638 the time of the satellite overpass (late morning) at the Puechabon EC site.

34 639 The use of an EB model to force the dry edge in the $LST_{norm} - f_{vg}$ feature space ($LST_{norm} -$
 35
 36 640 $f_{vg}(Tsd_{EB})$) is thus able to significantly reduce the bias and improve the sensitivity (slope) in flux
 37
 38 641 estimates for sites with different hc ($hc_{insitu} = 5.5/13 \text{ m}$ for Puechabon/Fontblanche). The $LST_{norm} -$
 39
 40 642 $f_{vg}(Tsd_{EB})$ method is a mixed contextual-EB approach, which is not new (Long and Singh, 2012;
 41
 42 643 Long et al., 2012; Moran et al., 1994; Sun et al., 2017). The novelty of this study lies in the
 43
 44 644 fact that the contextual-EB approach is based on a unique parameterization of the EB model. In
 45
 46 645 particular, it does not require complex spatial calibration and parameterization of aerodynamic
 47
 48 646 resistance, as is the case with conventional approaches based on EB model. Good performance of
 49
 50 647 $LST_{norm} - f_{vg}(Tsd_{EB})$ indicates that the simulated dry edge (Tsd_{EB}) reintroduces the meteorological
 51
 52 648 dynamics that influence H , LE , and EF and that is lacking in the contextually-derived dry edge
 53
 54 649 ($Tsd_{context}$) for $LST_{norm} - f_{vg}(Tsd_{context})$. The significant increase in the slope of the linear regression
 55
 56 650 for H , LE , and EF can be interpreted as the result of a more realistic temporal dynamics of the dry
 57
 58 651 edge simulated by the EB model, rather than that derived statistically from the contextual method.

1
2
3
4 652 Another advantage of using the EB model to force the dry edge is the sharp reduction in bias (in
5 653 absolute value) between $LST_{norm} - f_{vg}(Tsd_{context})$ and $LST_{norm} - f_{vg}(Tsd_{EB})$ approaches, for H , LE
6
7 654 and EF . This is a direct consequence of the underestimation of Tsd by the EB model, compared
8
9 655 with the contextual estimate ($Tsd_{context}$). Now two assumptions can be put forward to explain the
10
11 656 bias between contextual Tsd estimate ($Tsd_{context}$) and the level of the dry edge estimated by Tsd_{EB}
12
13 657 that provides good performances of the contextual method. The first one is based on directional
14
15 658 effects. Directional effects are due to the interaction between sub-pixel canopy structure, satellite
16
17 659 viewing angles and sun angles, which result in a decrease in LST (Michel et al., 2023). In par-
18
19 660 ticular, sub-pixel tree casting shadows have been shown to have an impact on the overestimation
20
21 661 of EF in Mediterranean forests (Penot and Merlin, 2023). The variability of hc within a pixel is
22
23 662 not taken into account in this study, and thus the possible directional effects on LST/LST_{norm} are
24
25 663 omitted. The second hypothesis is that, both Puechabon and Fontblanche forests sustain relatively
26
27 664 high H and low LE , as compared with other biomes. It has been shown that in arid ecosystems
28
29 665 (with $H \gg LE$), forests can maintain a lower LST than expected. Their greater roughness com-
30
31 666 pared to the soil increases the turbulent energy exchange ("canopy convective effect") between the
32
33 667 land and the atmosphere (Banerjee et al., 2018, 2017; Rotenberg and Yakir, 2010, 2011).

34 35 668 3.3. Sensitivity analysis

36 37 669 3.3.1. Sensitivity to Hc_{max}

38
39 670 The sensitivity analysis to Hc_{max} explores how different Hc_{max} values used to normalize LST
40
41 671 for hc effect affect the estimated H , LE and EF . This process involves comparing the performance
42
43 672 metrics (R , $RMS E$, slope, bias) of fluxes estimated from LST normalized using the All-Site Hc_{max}
44
45 673 ($Hc_{max} = 43$ m) and the Per-Site Hc_{max} ($Hc_{max} = 50/39$ m for Puechabon/Fontblanche) as reference.
46
47 674 Table 2 shows the differences in performance metrics between the brackets. Overall, the results
48
49 675 suggest that EF and flux estimates are poorly sensitive to such variations in Hc_{max} , as the differ-
50
51 676 ence in R is often zero. However, using the All-Site Hc_{max} instead of the Per-Site Hc_{max} slightly
52
53 677 reduces the performance metrics of the estimates for the Fontblanche EC site, whereas it slightly
54
55 678 improves the performance metrics for the Puechabon EC site. These findings corroborate the re-
56
57 679 sults in Section 3.1, which identified a significant uncertainty in (the daily retrieved) hc_{max} for the

1
2
3
4 680 Puechabon area. It was suggested that the relatively small hc range and its unimodal distribution
5 681 in the Puechabon study area does not allow for reliable and robust estimates of Hc_{max} . This is per-
6
7 682 fectly consistent with the improved flux and EF estimates for Puechabon site using the All-Site
8
9 683 Hc_{max} .

12 684 3.3.2. Sensitivity to meteorological data

14 685 The sensitivity analysis to meteorological data investigates how the uncertainty in meteorolo-
15 686 gical data propagates through the estimated H , LE , and EF . The SAFRAN reanalysis dataset
17 687 is assumed to be more uncertain at the site level than localized in situ meteorological measure-
18 688 ments. Figures 10 (d) (All-Site data) and 11 (d), 12 (d) (Per-Site data) display the turbulent flux
21 689 and EF estimates for the $LST_{norm} - f_{vg}(Tsd_{EB})$ approach when the EB model uses SAFRAN re-
23 690 analysis meteorological data as input (except for Rg). Tables 1 (All-Site data) and 2 (Per-Site data)
25 691 provide the performance metrics of $LST_{norm} - f_{vg}(Tsd_{EB})$ using the SAFRAN reanalysis dataset.
27 692 These results should be compared with those from the $LST - f_{vg}$, $LST_{norm} - f_{vg}(Tsd_{context})$, and
29 693 $LST_{norm} - f_{vg}(Tsd_{EB})$ approaches (using in situ meteorological data). Regardless of the dataset
31 694 (All-Site or Per-Site), the use of SAFRAN data in the $LST_{norm} - f_{vg}(Tsd_{EB})$ approach continues
33 695 to improve the results from the $LST - f_{vg}$ and $LST_{norm} - f_{vg}(Tsd_{context})$ approaches. Both bias
35 696 and slope are still significantly improved compared to the $LST_{norm} - f_{vg}(Tsd_{context})$ and $LST - f_{vg}$
37 697 approaches. These results are promising as they show that the method can be applied over large
38 698 areas without requiring in situ meteorological data. However, a slight underestimation (H) and
40 699 overestimation (LE and EF) occur relative to the $LST_{norm} - f_{vg}(Tsd_{EB})$ approach that uses in situ
42 700 meteorological data. In fact, SAFRAN tends to overestimate in situ T_{air} measurements (bias =
44 701 0.87 K), thus overestimating the position of the wet edge.

47 702 3.3.3. Sensitivity analysis to Cg

49 703 The sensitivity analysis to Cg (ratio of G to Rn) is conducted on H and LE estimates using in
51 704 situ meteorological data used as input to $LST_{norm} - f_{vg}(Tsd_{EB})$ approach. The H and LE estimated
53 705 from the $LST_{norm} - f_{vg}(Tsd_{EB})$ approach with $Cg = 0$ ($f_{vg} = 1$) are computed for the All-Site dataset.
55 706 The correlation R is not degraded relative to $LST_{norm} - f_{vg}(Tsd_{EB})$ with $Cg = 0.32$ (variations in
57 707 R are $-0.02 / 0.02$ for H / LE). Generally, the slope decreases relative to $LST_{norm} - f_{vg}(Tsd_{EB})$

1
2
3
4 708 with $Cg = 0.32$ (variations in slope are $-0.12 / -0.01$ for H/LE). Finally, as expected, the greatest
5
6 709 difference is in bias (variations in biases are $= -74 \text{ W.m}^{-2} / 73 \text{ W.m}^{-2}$ for H/LE). However, the
7
8 710 results for $LST_{norm} - f_{vg}(Tsd_{EB})$ with $Cg = 0$ are still significantly better than for the $LST - f_{vg}$ and
9
10 711 $LST_{norm} - f_{vg}(Tsd_{context})$ approaches, which demonstrates the robustness of the approach, whatever
11
12 712 the value of Cg .

13 14 15 713 **4. Conclusion**

16
17 714 To extend the applicability of thermal-based turbulent heat flux approaches to forests, this
18
19 715 study integrates the LiDAR-derived hc in the classical contextual method. In practice, Landsat
20
21 716 LST is normalised for LiDAR-derived hc effect, and the normalized LST (LST_{norm}) is used in the
22
23 717 $LST_{norm} - f_{vg}$ feature space to estimate H , LE and EF . The approach is tested using optical/thermal
24
25 718 data from Landsat-7/8/9 missions and in situ measurements collected at two French Mediterranean
26
27 719 forest sites – Puechabon and Fontblanche – between 2013 and 2022, providing 110 and 96 Landsat
28
29 720 scenes/overpass dates simultaneously with in situ EC monitoring, respectively.

30
31 721 In practice, the approach comprises four steps. First, LST is plotted as a function of hc within
32
33 722 each study area, and the slope of the upper edge of the obtained triangle is interpreted as the de-
34
35 723 crease rate of LST as a function of hc . The hc value extrapolated along the upper edge and at
36
37 724 which LST is equal to the air temperature is called hc_{max} , the threshold value above which LST is
38
39 725 no more sensitive to turbulent fluxes. Secondly, the median of hc_{max} (per site or for all sites) is used
40
41 726 to normalize LST for the hc effect, and LST_{norm} – the equivalent of LST for $hc = 0$ – is plotted as
42
43 727 a function of f_{vg} . Third, the wet edge of the $LST_{norm} - f_{vg}$ feature space is set to the air temperature
44
45 728 and two different strategies are tested to set the dry edge of the $LST_{norm} - f_{vg}$ space either to the
46
47 729 contextually-derived dry soil temperature ($Tsd_{context}$, $LST_{norm} - f_{vg}(Tsd_{context})$), or to the dry soil
48
49 730 temperature simulated by a simple soil EB model (Tsd_{EB} , $LST_{norm} - f_{vg}(Tsd_{EB})$). Fourth, simu-
50
51 731 lation results for $LST_{norm} - f_{vg}(Tsd_{context})$ and $LST_{norm} - f_{vg}(Tsd_{EB})$ and for the classical $LST - f_{vg}$
52
53 732 method (without normalization, $LST - f_{vg}$) are intercompared for data during a 9-year period at
54
55 733 Puechabon and Fontblanche EC sites.

56 734 Based on this work, the following conclusions can be drawn:

- 735 • It is found that the median of hc_{max} (Hc_{max}) is quite similar for both study areas: Hc_{max} is

736 estimated as 50 m and 39 m for Puechabon and Fontblanche, respectively, and 43 m for both

737 sites combined. Physically, Hc_{max} is the hc value at which LST is approximately equal to

738 T_{air} , whatever EF . For hc equal to or greater than Hc_{max} , LST is no longer coupled to

739 turbulent fluxes.
- 740 • The $LST - f_{vg}$ approach results in highly biased ($-162 \text{ W.m}^{-2} / 132 \text{ W.m}^{-2}$) and poorly

741 sensitive (slope $0.28 / 0.06$) estimates of H/LE when both EC sites are considered together.

742 These results are consistent with previous studies. Additionally, the error structures at each

743 site are distinct : the Fontblanche EC site has a bias three times greater for H/LE than

744 the Puechabon EC site. This discrepancy corresponds to the differences in canopy structure

745 between Puechabon ($hc_{insitu} = 5.5 \text{ m}$) and Fontblanche ($hc_{insitu} = 13 \text{ m}$). Normalizing for

746 the hc effect and forcing the dry edge to the contextually-derived dry bare soil temperature

747 ($LST_{norm} - f_{vg}(Tsd_{context})$) improves the correlation of H/LE ($R = 0.72 / 0.36$). However,

748 the bias remains large ($-161 \text{ W.m}^{-2} / 130 \text{ W.m}^{-2}$). One striking result is that normalization

749 produces similar error trends for both sites (EF biases = $0.25/0.22$ and slope = $0.06/0.13$ for

750 Puechabon/Fontblanche), allowing homogeneous error analysis between sites, irrespective

751 of differences in canopy structure.
- 752 • Normalizing for the hc effect and forcing the dry edge to the dry bare soil temperature

753 simulated by an EB model ($LST_{norm} - f_{vg}(Tsd_{EB})$) significantly reduces the bias (-30 W.m^{-2}

754 $/ -1 \text{ W.m}^{-2}$) and sensitivity (slope = $0.81 / 0.53$) of the estimated fluxes (H/LE). The increase

755 in the slope of the linear regression between satellite-derived and in situ H/LE indicates that

756 Tsd_{EB} efficiently reintroduces meteorological forcing temporal variability into the dry edge

757 determination of the $LST_{norm} - f_{vg}$ space.
- 758 • The sensitivity analysis carried out on $LST_{norm} - f_{vg}(Tsd_{EB})$ outputs to Hc_{max} , to the meteo-

759 rological data used as input to EB model and to the EB model Cg parameter shows that the

760 $LST_{norm} - f_{vg}(Tsd_{EB})$ approach is quite robust. Uncertainties in input data do not signifi-

761 cantly affect the results, and maintain the above conclusions.

1
2
3
4 762 Despite the promising results, the methodology of this study requires further examination.
5
6 763 First, the study focused on only two different sites. To assess the stability of Hc_{max} (approximately
7
8 764 40 m in this study), the methodology should be tested on other water-limited forest sites. This
9
10 765 would help determine whether Hc_{max} is site-independent or site-specific . Additionally, testing the
11
12 766 EB model used to estimate Tsd_{EB} under various meteorological and land cover conditions would
13
14 767 be beneficial. Indeed, $Tsd_{EB} (LST_{norm} - f_{vg}(Tsd_{EB}))$ generally underestimated $Tsd_{context} (LST_{norm} -$
15
16 768 $f_{vg}(Tsd_{context}))$, although the classical representation of the EB would suggest the opposite. In fact,
17
18 769 physical phenomena other than surface roughness can affect the LST on forests and therefore
19
20 770 cannot be normalized by hc alone. These phenomena, such as directional effects (Michel et al.,
21
22 771 2023) or “canopy convective effects” (Banerjee et al., 2017; Rotenberg and Yakir, 2010, 2011), are
23
24 772 not represented by classical EB models and need to be better understood. In our context, carrying
25
26 773 out different EC measurements in the same study area under different land use conditions (e.g.
27
28 774 different hc) could provide valuable information for assessing the actual position of the dry edge
29
30 775 of contextual feature spaces.

31 32 776 **Appendix A. EB model**

33
34 777 Dry bare soil temperature (Tsd_{EB}) is the solution of the surface energy balance (EB) equation
35
36 778 for dry conditions ($LE = 0$) over soil (Malbêteau et al., 2017; Stefan et al., 2015):

$$37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65
66
67
68
69
70
71
72
73
74
75
76
77
78
79
80
81
82
83
84
85
86
87
88
89
90
91
92
93
94
95
96
97
98
99
100
$$Rn(1 - Cg) = H \quad (A.1)$$$$

Where Cg [-] is the ground heat flux (G [$W.m^{-2}$]) to net radiation (Rn [$W.m^{-2}$]) ratio, equal
to 0.32 for bare soil (Kustas and Daughtry, 1990). Rn , the net radiation, is expressed using the
general equation:

$$Rn = (1 - \alpha_s) Rg + \epsilon_s (R_a - \sigma LST^4) \quad (A.2)$$

with α_s [-] being the bare soil albedo set equal to 0.20 (Puechabon) and 0.15 (Fontblanche)
(Napoly, 2016; Napoly et al., 2017), and ϵ_s [-] the emissivity of bare soil set equal to 0.97 (Liu
et al., 2007) for both sites, $\sigma = 5.670374 \cdot 10^{-8} W.m^{-2}.K^{-4}$ the Stefan-Boltzmann constant, and Rg

1
2
3
4 785 [W.m⁻²] the incoming shortwave radiation. R_a [W.m⁻²] is the downward atmospheric radiation
5
6 786 expressed as:

$$9 \quad R_a = \epsilon_{air} \sigma T_{air}^4 \quad (A.3)$$

10
11
12 787 with ϵ_{air} [-] being the effective atmospheric emissivity:

$$13 \quad \epsilon_{air} = 0.553 \left(\frac{e_{air}}{100} \right)^{\frac{1}{7}} \quad (A.4)$$

14
15
16
17
18 788 Where e_{air} [Pa] is the air vapor pressure linked to the saturated vapor pressure e_{sat} [Pa] at air
19
20 789 temperature T_{air} [K] using $0 \leq RH \leq 1$ [-] the relative humidity:

$$21 \quad e_{air} = e_{sat}(T_{air}) RH \quad (A.5)$$

22
23
24
25
26 790 With:

$$27 \quad e_{sat}(T) = 611 \exp\left(\frac{17.27T - 273.15}{T - 35.9}\right) \quad (A.6)$$

28
29
30 791 The sensible heat flux H [W.m⁻²] is expressed as :

$$31 \quad H = \rho C_p \frac{LST - T_{air}}{Rah} \quad (A.7)$$

32
33
34
35
36 792 With ρ [kg.m⁻³] being the air density and C_p [J.Kg⁻¹.K⁻¹] the air specific heat. We use
37
38 793 the "semi-empirical" formulation of Rah presented in Choudhury et al. (1986) and based on the
39
40 794 Richardson number Ri [-] to represent the importance of natural relative to forced convection:

$$41 \quad Rah = \frac{Rah_0}{(1 + 5Ri)^\eta} \quad (A.8)$$

42
43
44
45
46 795 With η [-] being a coefficient set to 0.75 in unstable conditions ($LST \geq T_{air}$) and 2 in stable
47
48 796 conditions ($LST < T_{air}$), and Rah_0 is the neutral aerodynamic resistance expressed as in Choud-
49
50 797 hury et al. (1986):

$$51 \quad Rah_0 = \frac{1}{k^2 WS} \ln\left(\frac{z-d}{z_{0m}}\right)^2 \quad (A.9)$$

1
2
3
4 798 With k [-] being the Von Karman constant, $d = 0$ [m] the zero displacement height over bare
5 799 soil (Nishida et al., 2003), z [m] the reference height of measurements, WS [$\text{m}\cdot\text{s}^{-1}$] the wind speed
6
7 800 measured at z , and $z_{0m} = 0.003$ m, the roughness length for momentum transfer. Note that classical
8
9 801 values for bare soil z_{0m} span the 0.001-0.009 m interval (Allen et al., 2007; Liu et al., 2007; Nishida
10
11 802 et al., 2003; Yang et al., 2008).

12
13 803 The Richardson number is expressed as in (Malbêteau et al., 2017; Stefan et al., 2015) :

$$Ri = \frac{gz(LST - T_{air})}{WS^2 T_{air}} \quad (\text{A.10})$$

14
15
16
17
18
19 804 With g [$\text{m}\cdot\text{s}^{-2}$] being the gravitational constant.
20
21

22 805 **References**

- 23
24
25 806 Aboutaleb, M., Torres-Rua, A.F., McKee, M., Kustas, W.P., Nieto, H., Alsina, M.M., White, A., Prueger, J.H., Mc-
26
27 807 Kee, L., Alfieri, J., Hips, L., Coopmans, C., Dokoozlian, N., 2020. Incorporation of unmanned aerial vehicle (uav)
28
29 808 point cloud products into remote sensing evapotranspiration models. *Remote Sensing* 12. doi:10.3390/rs12010050.
30
31 809 Adeline, K., Burchard-Levine, V., Andreu, A., Krapez, J.C., Chatelard, C., Baldocchi, D., Ustin, S., 2024. Comparison
32
33 810 between the trapezoid method and two energy balance models (TSEB and 3SEB) to estimate evapotranspiration
34
35 811 of a tree-grass ecosystem, in: *EGU General Assembly Conference Abstracts*, p. 10913. doi:10.5194/egusphere-
36
37 812 egu24-10913.
38
39 813 Alderotti, F., Bussotti, F., Brunetti, C., Ferrini, F., Gori, A., Pollastrini, M., 2024. Linking patterns of forest dieback
40
41 814 to triggering climatic and weather events: an overview on Mediterranean forests. *iForest - Biogeosciences and*
42
43 815 *Forestry*, 309–316doi:10.3832/ifor4545-017.
44
45 816 Allard, V., Ourcival, J.M., Rambal, S., Joffre, R., Rocheteau, A., 2008. Seasonal and annual variation of car-
46
47 817 bon exchange in an evergreen mediterranean forest in southern france. *Global Change Biology* 14, 714–725.
48
49 818 doi:https://doi.org/10.1111/j.1365-2486.2008.01539.x.
50
51 819 Allen, R.G., Tasumi, M., Trezza, R., 2007. Satellite-based energy balance for mapping evapotranspiration
52
53 820 with internalized calibration (metric)—model. *Journal of Irrigation and Drainage Engineering* 133, 380–394.
54
55 821 doi:10.1061/(ASCE)0733-9437(2007)133:4(380).
56
57 822 Amazirh, A., Merlin, O., Er-Raki, S., Gao, Q., Rivalland, V., Malbeteau, Y., Khabba, S., Escorihuela, M.J.,
58
59 823 2018. Retrieving surface soil moisture at high spatio-temporal resolution from a synergy between sentinel-1
60
61 824 radar and landsat thermal data: A study case over bare soil. *Remote Sensing of Environment* 211, 321–337.
62
63 825 doi:https://doi.org/10.1016/j.rse.2018.04.013.
64
65

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

826 Ameztegui, A., Coll, L., Cáceres, M.D., Morán-Ordóñez, A., 2024. Disturbance impacts on mediterranean
827 forests across climate and management scenarios. *Journal of Environmental Management* 371, 123193.
828 doi:<https://doi.org/10.1016/j.jenvman.2024.123193>.

829 An, N., Hemmati, S., Cui, Y.J., 2017. Assessment of the methods for determining net radiation at different time-
830 scales of meteorological variables. *Journal of Rock Mechanics and Geotechnical Engineering* 9, 239–246.
831 doi:<https://doi.org/10.1016/j.jrmge.2016.10.004>.

832 Banerjee, T., Brugger, P., De Roo, F., Kröniger, K., Yakir, D., Rotenberg, E., Mauder, M., 2018. Turbulent trans-
833 port of energy across a forest and a semiarid shrubland. *Atmospheric Chemistry and Physics* 18, 10025–10038.
834 doi:[10.5194/acp-18-10025-2018](https://doi.org/10.5194/acp-18-10025-2018).

835 Banerjee, T., De Roo, F., Mauder, M., 2017. Explaining the convective effect in canopy turbulence by means of
836 large-eddy simulation. *Hydrology and Earth System Sciences* 21, 2987–3000. doi:[10.5194/hess-21-2987-2017](https://doi.org/10.5194/hess-21-2987-2017).

837 Bartkowiak, P., Ventura, B., Jacob, A., Castelli, M., 2024. A copernicus-based evapotranspiration dataset at 100 m
838 spatial resolution over four mediterranean basins. *Earth System Science Data* 16, 4709–4734. doi:[10.5194/essd-16-4709-2024](https://doi.org/10.5194/essd-16-4709-2024).

840 Bottalico, F., Chirici, G., Giannini, R., Mele, S., Mura, M., Puxeddu, M., McRoberts, R.E., Valbuena, R., Travaglini,
841 D., 2017. Modeling mediterranean forest structure using airborne laser scanning data. *International Journal of*
842 *Applied Earth Observation and Geoinformation* 57, 145–153. doi:<https://doi.org/10.1016/j.jag.2016.12.013>.

843 Boulet, G., Mougenot, B., Lhomme, J.P., Fanise, P., Lili-Chabaane, Z., Olioso, A., Bahir, M., Rivalland, V., Jarlan,
844 L., Merlin, O., Coudert, B., Er-Raki, S., Lagouarde, J.P., 2015. The sparse model for the prediction of water stress
845 and evapotranspiration components from thermal infra-red data and its evaluation over irrigated and rainfed wheat.
846 *Hydrology and Earth System Sciences* 19, 4653–4672. doi:[10.5194/hess-19-4653-2015](https://doi.org/10.5194/hess-19-4653-2015).

847 Burchard-Levine, V., Nieto, H., Riaño, D., Kustas, W.P., Migliavacca, M., El-Madany, T.S., Nelson, J.A., Andreu, A.,
848 Carrara, A., Beringer, J., Baldocchi, D., Martín, M.P., 2022. A remote sensing-based three-source energy balance
849 model to improve global estimations of evapotranspiration in semi-arid tree-grass ecosystems. *Global Change*
850 *Biology* 28, 1493–1515. doi:<https://doi.org/10.1111/gcb.16002>.

851 Burchard-Levine, V., Nieto, H., Riaño, D., Migliavacca, M., El-Madany, T.S., Guzinski, R., Carrara, A., Martín, M.P.,
852 2021. The effect of pixel heterogeneity for remote sensing based retrievals of evapotranspiration in a semi-arid tree-
853 grass ecosystem. *Remote Sensing of Environment* 260, 112440. doi:<https://doi.org/10.1016/j.rse.2021.112440>.

854 Carlson, T., Ripley, D., 1997. On the relation between ndvi, fractional vegetation cover, and leaf area index. *Remote*
855 *Sensing of Environment* 62, 241–252. doi:[https://doi.org/10.1016/S0034-4257\(97\)00104-1](https://doi.org/10.1016/S0034-4257(97)00104-1).

856 Carlson, T.N., 2020. A brief analysis of the triangle method and a proposal for its operational implementation. *Remote*
857 *Sensing* 12. doi:[10.3390/rs12223832](https://doi.org/10.3390/rs12223832).

858 Castellaneta, M., Rita, A., Camarero, J.J., Colangelo, M., Ripullone, F., 2022. Declines in canopy greenness and
859 tree growth are caused by combined climate extremes during drought-induced dieback. *Science of The Total*

- 1
2
3
4 860 Environment 813, 152666. doi:<https://doi.org/10.1016/j.scitotenv.2021.152666>.
- 5 861 Chirouze, J., Boulet, G., Jarlan, L., Fieuzal, R., Rodriguez, J.C., Ezzahar, J., Er-Raki, S., Bigeard, G., Merlin, O.,
6
7 862 Garatuza-Payan, J., Watts, C., Chehbouni, G., 2014. Intercomparison of four remote-sensing-based energy balance
8
9 863 methods to retrieve surface evapotranspiration and water stress of irrigated fields in semi-arid climate. *Hydrology
10 864 and Earth System Sciences* 18, 1165–1188. doi:[10.5194/hess-18-1165-2014](https://doi.org/10.5194/hess-18-1165-2014).
- 11 865 Choudhury, B., Reginato, R., Idso, S., 1986. An analysis of infrared temperature observations over wheat and cal-
12
13 866 culation of latent heat flux. *Agricultural and Forest Meteorology* 37, 75–88. doi:[https://doi.org/10.1016/0168-
15 867 1923\(86\)90029-8](https://doi.org/10.1016/0168-
14 867 1923(86)90029-8).
- 16 868 Colangelo, M., Camarero, J.J., Battipaglia, G., Borghetti, M., De Micco, V., Gentilesca, T., Ripullone, F., 2017.
17
18 869 A multi-proxy assessment of dieback causes in a mediterranean oak species. *Tree Physiology* 37, 617–631.
19 870 doi:[10.1093/treephys/tpx002](https://doi.org/10.1093/treephys/tpx002).
- 21 871 Cook, M., Schott, J.R., Mandel, J., Raqueno, N., 2014. Development of an operational calibration methodology for
22
23 872 the landsat thermal data archive and initial testing of the atmospheric compensation component of a land surface
24 873 temperature (1st) product from the archive. *Remote Sensing* 6, 11244–11266. doi:[10.3390/rs61111244](https://doi.org/10.3390/rs61111244).
- 25 874 Cook, M.J., 2014. Atmospheric compensation for a landsat land surface temperature product. Rochester Institute of
26
27 875 Technology.
- 28
29 876 Courault, D., Bsaibes, A., Kpemlie, E., Hadria, R., Hagolle, O., Marloie, O., Hanocq, J.F., Olioso, A., Bertrand, N.,
30
31 877 Desfonds, V., 2008. Assessing the potentialities of formosat-2 data for water and crop monitoring at small regional
32 878 scale in south-eastern france. *Sensors* 8, 3460–3481. doi:[10.3390/s8053460](https://doi.org/10.3390/s8053460).
- 33
34 879 Crago, R., Brutsaert, W., 1996. Daytime evaporation and the self-preservation of the evaporative fraction and the
35 880 bowen ratio. *Journal of Hydrology* 178, 241–255. doi:[https://doi.org/10.1016/0022-1694\(95\)02803-X](https://doi.org/10.1016/0022-1694(95)02803-X).
- 36
37 881 Delogu, E., Boulet, G., Olioso, A., Garrigues, S., Brut, A., Tallec, T., Demarty, J., Soudani, K., Lagouarde, J.P., 2018.
38
39 882 Evaluation of the sparse dual-source model for predicting water stress and evapotranspiration from thermal infrared
40 883 data over multiple crops and climates. *Remote Sensing* 10. doi:[10.3390/rs10111806](https://doi.org/10.3390/rs10111806).
- 41
42 884 Dyderski, M.K., Paż, S., Frelich, L.E., Jagodziński, A.M., 2018. How much does climate change threaten european
43 885 forest tree species distributions? *Global Change Biology* 24, 1150–1163. doi:<https://doi.org/10.1111/gcb.13925>.
- 44
45 886 Gallego-Elvira, B., Olioso, A., Mira, M., Reyes-Castillo, S., Boulet, G., Marloie, O., Garrigues, S., Courault, D.,
46
47 887 Weiss, M., Chauvelon, P., Boutron, O., 2013. Evaspa (evapotranspiration assessment from space) tool: An
48 888 overview. *Procedia Environmental Sciences* 19, 303–310. doi:<https://doi.org/10.1016/j.proenv.2013.06.035>. four
49 889 Decades of Progress in Monitoring and Modeling of Processes in the Soil-Plant-Atmosphere System: Applications
50
51 890 and Challenges.
- 52
53 891 Gokmen, M., Vekerdy, Z., Verhoef, A., Verhoef, W., Batelaan, O., van der Tol, C., 2012. Integration of soil moisture
54 892 in sebs for improving evapotranspiration estimation under water stress conditions. *Remote Sensing of Environment*
55 893 121, 261–274. doi:<https://doi.org/10.1016/j.rse.2012.02.003>.

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

894 Gokool, S., Riddell, E., Jarman, C., Chetty, K., Feig, G., Thenga, H., 2020. Evaluating the accuracy of satellite-
895 derived evapotranspiration estimates acquired during conditions of water stress. *International Journal of Remote*
896 *Sensing* 41, 704–724. doi:10.1080/01431161.2019.1646940.

897 González-Dugo, M.P., Chen, X., Andreu, A., Carpintero, E., Gómez-Giraldez, P.J., Carrara, A., Su, Z., 2021. Long-
898 term water stress and drought assessment of mediterranean oak savanna vegetation using thermal remote sensing.
899 *Hydrology and Earth System Sciences* 25, 755–768. doi:10.5194/hess-25-755-2021.

900 Hartmann, H., Bastos, A., Das, A.J., Esquivel-Muelbert, A., Hammond, W.M., Martínez-Vilalta, J., McDowell, N.G.,
901 Powers, J.S., Pugh, T.A., Ruthrof, K.X., Allen, C.D., 2022. Climate change risks to global forest health: Emer-
902 gence of unexpected events of elevated tree mortality worldwide. *Annual Review of Plant Biology* 73, 673–702.
903 doi:https://doi.org/10.1146/annurev-arplant-102820-012804.

904 Hu, G., Jia, L., Menenti, M., 2015. Comparison of mod16 and isa-saf msg evapotranspiration products over europe
905 for 2011. *Remote Sensing of Environment* 156, 510–526. doi:https://doi.org/10.1016/j.rse.2014.10.017.

906 Hu, T., Mallick, K., Hitzelberger, P., Didry, Y., Boulet, G., Szantoi, Z., Koetz, B., Alonso, I., Pascolini-Campbell, M.,
907 Halverson, G., Cawse-Nicholson, K., Hulley, G., Hook, S., Bhattarai, N., Olioso, A., Roujean, J.L.C.H., Gamet,
908 P., Su, Z.B., 2023. Evaluating European ECOSTRESS Hub Evapotranspiration Products Retrieved from Three
909 Structurally Contrasting SEB Models over Europe. *Water Resources Research* doi:10.1029/2022WR034132.

910 IGN, 2024. Lidar h.d. — géoservices [www document]. [https://geoservices.ign.fr/l](https://geoservices.ign.fr/lidarhd#telechargementclassifiees)
911 [idarhd#telechargementclassifiees](https://geoservices.ign.fr/lidarhd#telechargementclassifiees) [accessed 10.04.24].

912 Jiang, C., Ryu, Y., 2016. Multi-scale evaluation of global gross primary productivity and evapotranspiration prod-
913 ucts derived from breathing earth system simulator (bess). *Remote Sensing of Environment* 186, 528–547.
914 doi:https://doi.org/10.1016/j.rse.2016.08.030.

915 Jiang, L., Islam, S., 1999. A methodology for estimation of surface evapotranspiration over large areas using remote
916 sensing observations. *Geophysical Research Letters* 26, 2773–2776. doi:https://doi.org/10.1029/1999GL006049.

917 Jiang, L., Islam, S., Guo, W., Singh Jutla, A., Senarath, S.U., Ramsay, B.H., Eltahir, E., 2009. A satellite-based
918 daily actual evapotranspiration estimation algorithm over south florida. *Global and Planetary Change* 67, 62–77.
919 doi:https://doi.org/10.1016/j.gloplacha.2008.12.008. changes in land use and water use and their consequences on
920 climate, including biogeochemical cycles.

921 Jones, H.G., Rotenberg, E., 2011. *Energy, Radiation and Temperature Regulation in Plants*. John Wiley & Sons, Ltd.
922 doi:https://doi.org/10.1002/9780470015902.a0003199.pub2.

923 Karnieli, A., Agam, N., Pinker, R.T., Anderson, M., Imhoff, M.L., Gutman, G.G., Panov, N., Goldberg, A., 2010. Use
924 of ndvi and land surface temperature for drought assessment: Merits and limitations. *Journal of Climate* 23, 618 –
925 633. doi:10.1175/2009JCLI2900.1.

926 Khan, M.S., Jeong, J., Choi, M., 2021. An improved remote sensing based approach for pre-
927 dicting actual evapotranspiration by integrating lidar. *Advances in Space Research* 68, 1732–1753.

- 1
2
3
4 928 doi:<https://doi.org/10.1016/j.asr.2021.04.017>.
- 5 929 Kustas, W.P., Daughtry, C.S., 1990. Estimation of the soil heat flux/net radiation ratio from spectral data. *Agricultural*
6
7 930 *and Forest Meteorology* 49, 205–223. doi:[https://doi.org/10.1016/0168-1923\(90\)90033-3](https://doi.org/10.1016/0168-1923(90)90033-3).
- 8
9 931 van der Kwast, J., Timmermans, W., Gieske, A., Su, Z., Olioso, A., Jia, L., Elbers, J., Karssenber, D., de Jong, S.,
10 932 2009. Evaluation of the surface energy balance system (sebs) applied to aster imagery with flux-measurements at
11 933 the sparac 2004 site (barrax, spain). *Hydrology and Earth System Sciences* 13, 1337–1347. doi:10.5194/hess-13-
12 1337-2009.
- 13 934
14 935 Liu, S., Lu, L., Mao, D., Jia, L., 2007. Evaluating parameterizations of aerodynamic resistance to heat transfer using
15 936 field measurements. *Hydrology and Earth System Sciences* 11, 769–783. doi:10.5194/hess-11-769-2007.
- 16 937 Long, D., Singh, V.P., 2012. A two-source trapezoid model for evapotranspiration (ttme) from satellite imagery.
17 938 *Remote Sensing of Environment* 121, 370–388. doi:<https://doi.org/10.1016/j.rse.2012.02.015>.
- 18 939 Long, D., Singh, V.P., Scanlon, B.R., 2012. Deriving theoretical boundaries to address scale dependencies
19 940 of triangle models for evapotranspiration estimation. *Journal of Geophysical Research: Atmospheres* 117.
20 941 doi:<https://doi.org/10.1029/2011JD017079>.
- 21 942 Ma, Y., Zhou, J., Liu, S., Zhang, W., Zhang, Y., Xu, Z., Song, L., Zhao, H., 2022. Estimation of evapotranspiration
22 943 using all-weather land surface temperature and variational trends with warming temperatures for the river source
23 944 region in southwest china. *Journal of Hydrology* 613, 128346. doi:<https://doi.org/10.1016/j.jhydrol.2022.128346>.
- 24 945 Malbêteau, Y., Merlin, O., Gascoin, S., Gastellu-Etchegorry, J.P., Mattar, C., Olivera-Guerra, L.E., Khabba, S.P.,
25 946 Jarlan, L., 2017. Correcting land surface temperature data for elevation and illumination effects in mountainous
26 947 areas: A case study using ASTER data over a steep-sided valley in Morocco. *Remote Sensing of Environment* 189,
27 948 25 – 39. doi:10.1016/j.rse.2016.11.010.
- 28 949 Mallick, K., Sulis, M., Jiménez-Rodríguez, C.D., Hu, T., Jia, A., Drewry, D.T., 2024. Soil and atmospheric
29 950 drought explain the biophysical conductance responses in diagnostic and prognostic evaporation models over
30 951 two contrasting european forest sites. *Journal of Geophysical Research: Biogeosciences* 129, e2023JG007784.
31 952 doi:<https://doi.org/10.1029/2023JG007784>. e2023JG007784 2023JG007784.
- 32 953 Martin-Ducup, O., Dupuy, J.L., Soma, M., Guerra-Hernandez, J., Marino, E., Fernandes, P.M., Just, A., Corbera, J.,
33 954 Touthkov, M., Sorribas, C., Bock, J., Piboule, A., Pirotti, F., Pimont, F., 2025. Unlocking the potential of airborne
34 955 lidar for direct assessment of fuel bulk density and load distributions for wildfire hazard mapping. *Agricultural and*
35 956 *Forest Meteorology* 362, 110341. doi:<https://doi.org/10.1016/j.agrformet.2024.110341>.
- 36 957 Maurer, K.D., Bohrer, G., Kenny, W.T., Ivanov, V.Y., 2015. Large-eddy simulations of surface roughness parameter
37 958 sensitivity to canopy-structure characteristics. *Biogeosciences* 12, 2533–2548. doi:10.5194/bg-12-2533-2015.
- 38 959 Merlin, O., 2013. An original interpretation of the wet edge of the surface temperature–albedo space to estimate crop
39 960 evapotranspiration (seb-1s), and its validation over an irrigated area in northwestern mexico. *Hydrology and Earth*
40 961 *System Sciences* 17, 3623–3637. doi:10.5194/hess-17-3623-2013.

- 1
2
3
4 962 Michel, J., Hagolle, O., Hook, S.J., Roujean, J.L., Gamet, P., 2023. Quantifying thermal infra-red directional
5 963 anisotropy using master and landsat-8 simultaneous acquisitions. *Remote Sensing of Environment* 297, 113765.
6 964 doi:<https://doi.org/10.1016/j.rse.2023.113765>.
- 7
8 965 Moran, M., Clarke, T., Inoue, Y., Vidal, A., 1994. Estimating crop water deficit using the relation be-
9 966 tween surface-air temperature and spectral vegetation index. *Remote Sensing of Environment* 49, 246–263.
10 967 doi:[https://doi.org/10.1016/0034-4257\(94\)90020-5](https://doi.org/10.1016/0034-4257(94)90020-5).
- 11
12 968 Moreno, M., Simioni, G., Cochard, H., Doussan, C., Guillemot, J., Decarsin, R., Fernandez-Conradi, P., Dupuy, J.L.,
13 969 Trueba, S., Pimont, F., Ruffault, J., Jean, F., Marloie, O., Martin-StPaul, N.K., 2024. Isohydraulicity and hydraulic
14 970 isolation explain reduced hydraulic failure risk in an experimental tree species mixture. *Plant Physiology* 195,
15 971 2668–2682. doi:[10.1093/plphys/kiae239](https://doi.org/10.1093/plphys/kiae239).
- 16
17 972 Morillas, L., García, M., Nieto, H., Villagarcia, L., Sandholt, I., Gonzalez-Dugo, M., Zarco-Tejada,
18 973 P., Domingo, F., 2013. Using radiometric surface temperature for surface energy flux estimation in
19 974 mediterranean drylands from a two-source perspective. *Remote Sensing of Environment* 136, 234–246.
20 975 doi:<https://doi.org/10.1016/j.rse.2013.05.010>.
- 21
22 976 Napoly, A., 2016. Apport de paramétrisations avancées des processus liés à la végétation dans les modèles de surface
23 977 pour la simulation des flux atmosphériques et hydrologiques. Theses. Institut National Polytechnique de Toulouse
24 978 - INPT.
- 25
26 979 Napoly, A., Boone, A., Samuelsson, P., Gollvik, S., Martin, E., Seferian, R., Carrer, D., Decharme, B., Jarlan, L.,
27 980 2017. The interactions between soil–biosphere–atmosphere (isba) land surface model multi-energy balance (meb)
28 981 option in surfexv8 – part 2: Introduction of a litter formulation and model evaluation for local-scale forest sites.
29 982 *Geoscientific Model Development* 10, 1621–1644. doi:[10.5194/gmd-10-1621-2017](https://doi.org/10.5194/gmd-10-1621-2017).
- 30
31 983 Neale, C.M.U., Geli, H., Taghvaeian, S., Masih, A., Pack, R.T., Simms, R.D., Baker, M., Milliken, J.A., O’Meara, S.,
32 984 Witherall, A.J., 2011. Estimating evapotranspiration of riparian vegetation using high resolution multispectral, ther-
33 985 mal infrared and lidar data, in: Neale, C.M.U., Maltese, A. (Eds.), *Remote Sensing for Agriculture, Ecosystems,*
34 986 *and Hydrology XIII*, International Society for Optics and Photonics. SPIE. p. 81740P. doi:[10.1117/12.903246](https://doi.org/10.1117/12.903246).
- 35
36 987 Nishida, K., Nemani, R.R., Running, S.W., Glassy, J.M., 2003. An operational remote sensing algorithm of land sur-
37 988 face evaporation. *Journal of Geophysical Research: Atmospheres* 108. doi:<https://doi.org/10.1029/2002JD002062>.
- 38
39 989 Njuki, S.M., Mannaerts, C.M., Su, Z., 2023. Accounting for turbulence-induced canopy heat transfer in the simulation
40 990 of sensible heat flux in sebs model. *Remote Sensing* 15. doi:[10.3390/rs15061578](https://doi.org/10.3390/rs15061578).
- 41
42 991 Ollivier, C., Olioso, A., Carrière, S.D., Boulet, G., Chalikakis, K., Chanzy, A., Charlier, J.B., Combemale, D., Davi,
43 992 H., Emblanch, C., Marloie, O., Martin-StPaul, N., Mazzilli, N., Simioni, G., Weiss, M., 2021. An evapotranspira-
44 993 tion model driven by remote sensing data for assessing groundwater resource in karst watershed. *Science of The*
45 994 *Total Environment* 781, 146706. doi:<https://doi.org/10.1016/j.scitotenv.2021.146706>.
- 46
47 995 Penot, V., Merlin, O., 2023. Estimating the water deficit index of a mediterranean holm oak forest from landsat
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

996 optical/thermal data: A phenomenological correction for trees casting shadow effects. *IEEE Journal of Selected*
997 *Topics in Applied Earth Observations and Remote Sensing* 16, 5867–5880. doi:10.1109/JSTARS.2023.3288360.
998 Peñuelas, J., Sardans, J., Filella, I., Estiarte, M., Llusià, J., Ogaya, R., Carnicer, J., Bartrons, M., Rivas-Ubach, A.,
999 Grau, O., Peguero, G., Margalef, O., Pla-Rabés, S., Stefanescu, C., Asensio, D., Preece, C., Liu, L., Verger, A.,
1000 Barbeta, A., Achotegui-Castells, A., Gargallo-Garriga, A., Sperlich, D., Farré-Armengol, G., Fernández-Martínez,
1001 M., Liu, D., Zhang, C., Urbina, I., Camino-Serrano, M., Vives-Inгла, M., Stocker, B.D., Balzarolo, M., Guerrieri,
1002 R., Peaucelle, M., Marañón-Jiménez, S., Bórnez-Mejías, K., Mu, Z., Descals, A., Castellanos, A., Terradas, J.,
1003 2017. Impacts of global change on mediterranean forests and their services. *Forests* 8. doi:10.3390/f8120463.
1004 Potapov, P., Li, X., Hernandez-Serna, A., Tyukavina, A., Hansen, M.C., Kommareddy, A., Pickens, A., Turubanova,
1005 S., Tang, H., Silva, C.E., Armston, J., Dubayah, R., Blair, J.B., Hofton, M., 2021. Mapping global forest
1006 canopy height through integration of gedi and landsat data. *Remote Sensing of Environment* 253, 112165.
1007 doi:https://doi.org/10.1016/j.rse.2020.112165.
1008 Purdy, A.J., Fisher, J.B., Goulden, M.L., Famiglietti, J.S., 2016. Ground heat flux: An analytical review of 6
1009 models evaluated at 88 sites and globally. *Journal of Geophysical Research: Biogeosciences* 121, 3045–3059.
1010 doi:https://doi.org/10.1002/2016JG003591.
1011 Qiu, S., Zhu, Z., Shang, R., Crawford, C.J., 2021. Can landsat 7 preserve its science capability with a drifting orbit?
1012 *Science of Remote Sensing* 4, 100026. doi:https://doi.org/10.1016/j.srs.2021.100026.
1013 Rambal, S., Ourcival, J.M., Joffre, R., Mouillot, F., Nouvellon, Y., Reichstein, M., Rocheteau, A., 2003. Drought
1014 controls over conductance and assimilation of a mediterranean evergreen ecosystem: scaling from leaf to canopy.
1015 *Global Change Biology* 9, 1813–1824. doi:https://doi.org/10.1111/j.1365-2486.2003.00687.x.
1016 Rotenberg, E., Yakir, D., 2010. Contribution of semi-arid forests to the climate system. *Science* 327, 451–454.
1017 doi:10.1126/science.1179998.
1018 Rotenberg, E., Yakir, D., 2011. Distinct patterns of changes in surface energy budget associated with forestation in the
1019 semiarid region. *Global Change Biology* 17, 1536–1548. doi:https://doi.org/10.1111/j.1365-2486.2010.02320.x.
1020 Roussel, J.R., Auty, D., Coops, N.C., Tompalski, P., Goodbody, T.R., Meador, A.S., Bourdon, J.F., de Boissieu,
1021 F., Achim, A., 2020. lidar: An r package for analysis of airborne laser scanning (als) data. *Remote Sensing of*
1022 *Environment* 251, 112061. doi:https://doi.org/10.1016/j.rse.2020.112061.
1023 Ryu, Y., Baldocchi, D.D., Black, T.A., Detto, M., Law, B.E., Leuning, R., Miyata, A., Reichstein, M., Var-
1024 gas, R., Ammann, C., Beringer, J., Flanagan, L.B., Gu, L., Hutley, L.B., Kim, J., McCaughey, H., Moors,
1025 E.J., Rambal, S., Vesala, T., 2012. On the temporal upscaling of evapotranspiration from instantaneous re-
1026 mote sensing measurements to 8-day mean daily-sums. *Agricultural and Forest Meteorology* 152, 212–222.
1027 doi:https://doi.org/10.1016/j.agrformet.2011.09.010.
1028 Schmidt, G., Jenkerson, C., Masek, J., Vermote, E., Gao, F., 2013. Landsat ecosystem disturbance adaptive processing
1029 system (ledaps) algorithm description. U.S. Geol. Surv. Open File Rep. 1057.

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

1030 Schwartz, M., Ciais, P., Ottlé, C., De Truchis, A., Vega, C., Fayad, I., Brandt, M., Fensholt, R., Baghdadi, N., Morneau,
1031 F., Morin, D., Guyon, D., Dayau, S., Wigneron, J.P., 2024. High-resolution canopy height map in the landes forest
1032 (france) based on gedi, sentinel-1, and sentinel-2 data with a deep learning approach. *International Journal of*
1033 *Applied Earth Observation and Geoinformation* 128, 103711. doi:<https://doi.org/10.1016/j.jag.2024.103711>.

1034 Shaik, R.U., Jallu, S.B., Doctor, K., 2023. Unveiling temperature patterns in tree canopies across diverse heights and
1035 types. *Remote Sensing* 15. doi:10.3390/rs15082080.

1036 Shaw, R.H., Pereira, A., 1982. Aerodynamic roughness of a plant canopy: A numerical experiment. *Agricultural*
1037 *Meteorology* 26, 51–65. doi:[https://doi.org/10.1016/0002-1571\(82\)90057-7](https://doi.org/10.1016/0002-1571(82)90057-7).

1038 Simioni, G., Durand-Gillmann, M., Huc, R., 2013. Asymmetric competition increases leaf inclination effect on light
1039 absorption in mixed canopies. *Annals of Forest Science* 70, 123–131. doi:10.1007/s13595-012-0246-8.

1040 Simioni, G., Marie, G., Davi, H., Martin-St Paul, N., Huc, R., 2020. Natural forest dynamics have more influence
1041 than climate change on the net ecosystem production of a mixed mediterranean forest. *Ecological Modelling* 416,
1042 108921. doi:<https://doi.org/10.1016/j.ecolmodel.2019.108921>.

1043 Simioni, G., Marie, G., Huc, R., 2016. Influence of vegetation spatial structure on growth and wa-
1044 ter fluxes of a mixed forest: Results from the notg 3d model. *Ecological Modelling* 328, 119–135.
1045 doi:<https://doi.org/10.1016/j.ecolmodel.2016.02.004>.

1046 Stefan, V.G., Merlin, O., Er-Raki, S., Escorihuela, M.J., Khabba, S., 2015. Consistency between in situ, model-derived
1047 and high-resolution-image-based soil temperature endmembers: Towards a robust data-based model for multi-
1048 resolution monitoring of crop evapotranspiration. *Remote Sensing* 7, 10444–10479. doi:10.3390/rs70810444.

1049 Stisen, S., Sandholt, I., Nørgaard, A., Fensholt, R., Jensen, K.H., 2008. Combining the triangle method with thermal
1050 inertia to estimate regional evapotranspiration — applied to msg-seviri data in the senegal river basin. *Remote*
1051 *Sensing of Environment* 112, 1242–1255. doi:<https://doi.org/10.1016/j.rse.2007.08.013>.

1052 Su, Z., 2002. The surface energy balance system (sebs) for estimation of turbulent heat fluxes. *Hydrology and Earth*
1053 *System Sciences* 6, 85–100. doi:10.5194/hess-6-85-2002.

1054 Sun, H., Wang, Y., Liu, W., Yuan, S., Nie, R., 2017. Comparison of three theoretical methods for determining dry and
1055 wet edges of the lst/fvc space: Revisit of method physics. *Remote Sensing* 9. doi:10.3390/rs9060528.

1056 Tang, R., Li, Z.L., Tang, B., 2010. An application of the ts–vi triangle method with enhanced edges determination
1057 for evapotranspiration estimation from modis data in arid and semi-arid regions: Implementation and validation.
1058 *Remote Sensing of Environment* 114, 540–551. doi:<https://doi.org/10.1016/j.rse.2009.10.012>.

1059 Tian, X., Li, Z., van der Tol, C., Su, Z., Li, X., He, Q., Bao, Y., Chen, E., Li, L., 2011. Estimating zero-plane
1060 displacement height and aerodynamic roughness length using synthesis of lidar and spot-5 data. *Remote Sensing*
1061 *of Environment* 115, 2330–2341. doi:<https://doi.org/10.1016/j.rse.2011.04.033>.

1062 Trebs, I., Mallick, K., Bhattarai, N., Sulis, M., Cleverly, J., Woodgate, W., Silberstein, R., Hinko-Najera,
1063 N., Beringer, J., Meyer, W.S., Su, Z., Boulet, G., 2021. The role of aerodynamic resistance in ther-

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65

mal remote sensing-based evapotranspiration models. *Remote Sensing of Environment* 264, 112602. doi:<https://doi.org/10.1016/j.rse.2021.112602>.

Venturini, V., Bisht, G., Islam, S., Jiang, L., 2004. Comparison of evaporative fractions estimated from avhrr and modis sensors over south florida. *Remote Sensing of Environment* 93, 77–86. doi:<https://doi.org/10.1016/j.rse.2004.06.020>.

Vermote, E., Justice, C., Claverie, M., Franch, B., 2016. Preliminary analysis of the performance of the landsat 8/oli land surface reflectance product. *Remote Sensing of Environment* 185, 46–56. doi:<https://doi.org/10.1016/j.rse.2016.04.008>. landsat 8 Science Results.

Vicente, E., Vilagrosa, A., Ruiz-Yanetti, S., Manrique-Alba, n., González-Sanchís, M., Moutahir, H., Chirino, E., Del Campo, A., Bellot, J., 2018. Water balance of mediterranean quercus ilex l. and pinus halepensis mill. forests in semiarid climates: A review in a climate change context. *Forests* 9. doi:10.3390/f9070426.

Vidal, A., Devaux-Ros, C., 1995. Evaluating forest fire hazard with a landsat tm derived water stress index. *Agricultural and Forest Meteorology* 77, 207–224. doi:[https://doi.org/10.1016/0168-1923\(95\)02262-V](https://doi.org/10.1016/0168-1923(95)02262-V). thermal Remote Sensing of the Energy and Water Balance over Vegetation.

Vidal, J.P., Martin, E., Franchistéguy, L., Baillon, M., Soubeyroux, J.M., 2010. A 50-year high-resolution atmospheric reanalysis over france with the safran system. *International Journal of Climatology* 30, 1627–1644. doi:10.1002/joc.2003.

Virlet, N., Lebourgeois, V., Martinez, S., Costes, E., Labbé, S., Regnard, J.L., 2014. Stress indicators based on airborne thermal imagery for field phenotyping a heterogeneous tree population for response to water constraints. *Journal of Experimental Botany* 65, 5429–5442. doi:10.1093/jxb/eru309.

Wang, K., Li, Z., Cribb, M., 2006. Estimation of evaporative fraction from a combination of day and night land surface temperatures and ndvi: A new method to determine the priestley–taylor parameter. *Remote Sensing of Environment* 102, 293–305. doi:<https://doi.org/10.1016/j.rse.2006.02.007>.

Yang, K., Koike, T., Ishikawa, H., Kim, J., Li, X., Liu, H., Liu, S., Ma, Y., Wang, J., 2008. Turbulent flux transfer over bare-soil surfaces: Characteristics and parameterization. *Journal of Applied Meteorology and Climatology* 47, 276 – 290. doi:10.1175/2007JAMC1547.1.

Zhang, D., Tang, R., Zhao, W., Tang, B., Wu, H., Shao, K., Li, Z.L., 2014. Surface soil water content estimation from thermal remote sensing based on the temporal variation of land surface temperature. *Remote Sensing* 6, 3170–3187. doi:10.3390/rs6043170.

Zhang, Z., Li, X., Liu, H., 2022. Biophysical feedback of forest canopy height on land surface temperature over contiguous united states. *Environmental Research Letters* 17, 034002. doi:10.1088/1748-9326/ac4657.

Chapitre 6

Mise en évidence des effets directionnels sur l'estimation du stress hydrique en forêt méditerranéenne à partir de données optiques/thermiques et proposition d'une correction phénoménologique

6.1 Introduction

Les effets directionnels à l'échelle sub-pixellaire résultent de l'interaction entre les angles de vue du satellite, les angles d'éclairement du soleil et la géométrie tridimensionnelle sub-pixellaire de la surface (Michel et al., 2023). Ces effets se matérialisent par l'effet des ombres portées sur la LST mesurée. Les deux premiers facteurs (angles solaires et angles de vue du satellite) sont connus avec une grande précision en tout lieu et en tout temps alors que la géométrie de la surface est très difficile à estimer. A ce jour, il n'existe pas de solution opérationnelle permettant de prendre en compte les effets directionnels à la résolution des capteurs des satellites actuels (Landsat 100 m, MODIS 1000 m) et à venir (TRISHNA 57-50 m) et ne dépendant que des conditions du pixel considéré. Dans la première Section 6.2, l'effet des ombres portées est mis en évidence sur l'estimation de EF et deux corrections phénoménologiques sont proposées. Cette Section s'appuie sur les méthodes développées dans l'article disponible en Section 6.5. Cet article étudie l'effet des ombres portées et sa correction sur le site de Puechabon. Dans cet article, l'indice de stress nommé WDI est une estimation de $1-EF$. Pour plus de cohérence avec le Chapitre précédent, les résultats de l'article sont adaptés à l'estimation et la correction de EF . Ensuite, la Section 6.3 étudie la synergie entre les résultats du Chapitre 5 et ceux de la Section 6.2. Enfin la Section 6.4 conclut ce Chapitre.

6.2 Mise en évidence et correction de l'effet des ombres portées

Dans cette Section, les méthodes de correction de l'effet des ombres portées proposées dans l'article joint à ce Chapitre (voir Section 6.5) sont admises mais présentées (Section 6.2.1) et discutées (Section 6.2.2). En particulier, alors que l'article n'a étudié que le site Eddy Covariance de Puechabon présenté au Chapitre 5, cette Section étend l'étude de l'effet des ombres portées au site Eddy Covariance de Fontblanche, tout en diversifiant les conditions de surface et météorologiques rencontrées dans l'aire d'étude de Puechabon. Ensuite, la correction opérationnelle proposée dans l'article est mise en œuvre pour estimer le stress hydrique sur les sites du Réseau Hydrique et pour la prédiction de la sévérité potentielle (Section 6.2.3). Enfin la Section 6.2.4 synthétise les principaux résultats et suggère des améliorations aux méthodes proposées dans l'article joint à ce Chapitre.

6.2.1 Matériel et méthodes

Sites et aires d'étude, données météorologiques et de télédétection

Dans l'article disponible en Section 6.5, l'aire d'étude de Puechabon couvre 2100 ha et la période d'étude est comprise entre mai et septembre, de 2015 à 2021. Afin d'intégrer plus de variabilité dans les données, l'ensemble des sites Eddy Covariance et données du Chapitre 5 sont utilisés. Les mois d'étude s'étendent de mai à septembre (idem article). Ainsi des conditions météorologiques et de surface plus hétérogènes sont intégrées dans l'analyse afin de tester la robustesse des résultats obtenus dans l'article.

Méthodes

L'estimation de EF (EF_{sat}) par l'approche $LST - f_{vg}$ est détaillée au Chapitre 2. Elle sert de référence. La méthode de correction des ombres portées repose sur les hypothèses que 1) l'effet des ombres portées sur EF peut être approximé par l'angle zénithal solaire θ_S , 2) l'effet des ombres portées affecte particulièrement les conditions durant lesquelles le stress hydrique est élevé (EF faible) et 3) l'erreur sur EF attribuée aux ombres portées est minimale pour θ_S proche du nadir. La figure 6.1 résume les deux approches permettant 1) d'évaluer ces hypothèses (Correction calibrée Site) et 2) de mettre au point une correction valable en tout lieu et en tout temps (Correction Auto-calibrée). Dans les deux cas il suffit de déterminer les coefficients a (effet marginal des ombres supposé constant quel que soit θ_S) et b (angle zénithal solaire pour lequel l'effet des ombres sont négligeables) de correction de l'erreur attribuée à l'effet des ombres ΔEF :

$$\Delta EF = a(\theta_S - b) \quad (6.1)$$

Les conditions météorologiques permettant de calibrer ces deux paramètres correspondent à des conditions où l'effet des ombres portées est supposé maximal, ie en conditions de stress hydrique très élevé. Pour déterminer ces conditions, le cumul de pluie sur 15 jours précédant le passage du satellite est utilisé. Le jeu de calibration "JdD Très Sec" correspond aux dates entre juin et septembre où le cumul de pluie sur 15 jours est inférieur au quantile 0.25 du cumul de pluie sur l'ensemble de la période d'étude. De manière similaire, le "JdD Sec" (respectivement "JdD Humide") est défini si le cumul de pluie sur 15 jours est inférieur (respectivement supérieur) au quantile 0.50 du cumul de pluie sur l'ensemble de la période d'étude. Ces deux jeux de données sont à vocation d'évaluation. L'ensemble du jeu de données est appelé "JdD Complet".

Deux approches sont mises au point pour calibrer a et b sur le JdD Très Sec :

- si les données in situ de EF sont disponibles alors les coefficients a_{site} et b_{site} correspondent aux coefficients de la régression linéaire de l'erreur in situ ($EF_{sat} - EF_{insitu}$) sur θ_S (Calibration Site).

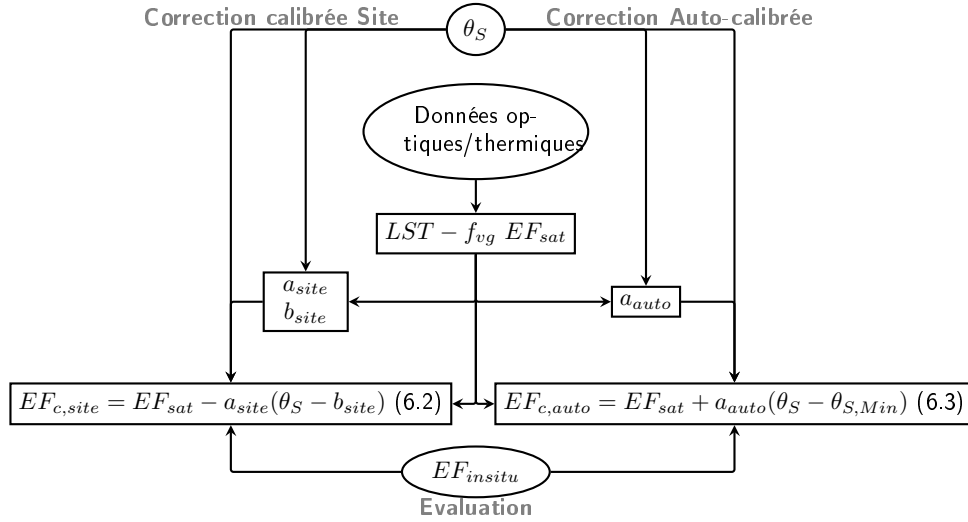


FIGURE 6.1 – Schéma de la méthodologie globale pour estimer et corriger EF de l'effet des ombres portées approximé par l'angle zénithal solaire (θ_S), pour calibrer cette correction à partir de données in situ (Correction calibrée Site, à gauche) ou de données de télédétection uniquement (Correction Auto-calibrée, à droite) et pour évaluer l'efficacité de la correction à partir des données in situ sur les sites Eddy Covariance (en bas).

- s'il n'y a pas de données in situ de flux, alors le coefficients a_{auto} correspond à la pente du bord linéaire supérieur du nuage de points de $1-EF_{sat}$ vs θ_S (Auto-Calibration). b_{auto} est pris égal au minimum de θ_S observé sur la position considérée ($\theta_{S,Min}$). Les effets des ombres sont supposés négligeables quand θ_S est minimum et que l'angle zénithal de vue du satellite est négligeable (angle zénithal de vue Landsat inférieur à 8° , Michel et al. (2023)).

La correction de l'effet des ombres portées sur l'ensemble du jeu de données, dite Correction calibrée Site (voir figure 6.1 gauche), est déduite de la Calibration Site via l'équation :

$$EF_{c,site} = EF_{sat} - a_{site}(\theta_S - b_{site}) \quad (6.2)$$

La correction opérationnelle de l'effet des ombres portées sur l'ensemble du jeu de données, dite Correction Auto-calibrée (voir figure 6.1 droite), est déduite de l'Auto-Calibration via l'équation :

$$EF_{c,auto} = EF_{sat} + a_{auto}(\theta_S - \theta_{S,Min}) \quad (6.3)$$

Dans les deux cas, les résultats des corrections sont évalués au regard de EF_{insitu} .

6.2.2 Résultats et discussion

Dans une première Section, les principaux résultats de l'article sont présentés. Puis les deux approches de calibration et de correction sont mises en œuvre sur les deux sites Eddy Covariance. En particulier le choix du jeu de données de calibration des corrections et de l'influence des corrections sur la qualité des résultats en fonction des conditions (humides, sèches) sont testés et discutés en regard des résultats de l'article.

Synthèse des résultats de l'article

Les hypothèses de l'effet des ombres portées sur l'erreur d'estimation de EF issue de l'approche $LST - f_{vg}$ ont été validées sur le site de Puechabon ainsi que les deux corrections (voir Section 6.5). Tout d'abord, la Correction calibrée Site dérivée de la Calibration Site calibrée sur le JdD Complet ne fournit pas une correction d'aussi bonne qualité ($R = 0.57$, pente=0.50 et biais=0.00 vs $R = 0.32$, pente=0.21 et biais=0.10 sans correction) que si elle est dérivée de la Calibration Site sur le JdD Très Sec ($R = 0.62$, pente=0.63 et biais=-0.02). Ce résultat justifie que les calibrations s'effectuent sur le JdD Très Sec dont les conditions sont physiquement propices à la calibration de l'effet des ombres portées. En effet, les conditions très sèches favorisent un fort contraste entre surface ensoleillée (LST élevée, stress hydrique important) et surface à l'ombre (LST proche de T_{air} , stress hydrique apparent faible) au sein d'un pixel satellitaire. Ces conditions sont donc propices à un effet des ombres importants (sous-estimation du stress hydrique). La Calibration Site sur le JdD Très Sec met en évidence une relation linéaire strictement croissante et significative de l'erreur in situ ΔEF avec θ_S ($R^2 = 0.59$) et une erreur in situ négligeable pour $\theta_S \approx \theta_{S,Min}$. Plus particulièrement, $a_{site} = 0.020$ est strictement positif. Ce résultat démontre une augmentation physiquement cohérente de l'erreur avec θ_S , proxy des ombres portées. Par ailleurs, $b_{site} = 25.6^\circ \approx \theta_{S,Min} = 25.7^\circ$: l'effet des ombres sont négligeables pour $\theta_S \approx \theta_{S,Min}$. L'Auto-Calibration sur le JdD Très Sec montre une décroissance linéaire du bord supérieur de l'espace 1- EF_{sat} vs θ_S avec $a_{auto} = -0.013$. En l'absence de l'effet des ombres portées, ce bord supérieur qui modélise les valeurs maximales de EF_{sat} avec θ_S devrait être plat en conditions très sèches. L'Auto-Calibration fournit ainsi une méthode opérationnelle pour les corriger. Enfin les Correction calibrée Site et Correction Auto-calibrée calibrées sur le JdD Très Sec fournissent une correction de qualité de EF_{sat} ($R = 0.62$ et $R = 0.57$ / pente=0.63 et pente =0.50 pour Correction calibrée Site et Correction Auto-calibrée respectivement) en particulier pour les données du JdD Sec. Sur le JdD Humide, dont les conditions sont moins favorables à un effet significatif des ombres portées, les corrections impliquent une augmentation du biais absolu.

Résultats et discussion de la calibration des coefficients a et b

La figure 6.2 présente la Calibration Site pour les deux sites Eddy Covariance et les jeux de données JdD Complet ((a) et (c)) et JdD Très Sec ((b) et (e)). Pour le site de Puechabon (voir figure 6.2 (a) et (b)), la calibration des paramètres a_{site} et b_{site} est en accord avec les conclusions de l'article. La corrélation R entre l'erreur in situ et θ_S est moindre pour le JdD Complet ($R = 0.30$) que pour le JdD Très Sec ($R = 0.62$). Les coefficients a_{site} sont positifs (0.0068 et 0.014 pour le JdD Complet et le JdD Très Sec respectivement) ce qui est physiquement cohérent : l'erreur sur EF augmente avec θ_S du fait d'une augmentation de l'effet des ombres portées approximé par θ_S . Les coefficients b_{site} sont assez similaires (20.6° et 22.1°) et sont inférieurs au minimum du zénith solaire ($\theta_{S,Min} = 25.7^\circ$). La cohérence physique de b_{site} qui quantifie θ_S pour lequel l'effet des ombres est négligeable est néanmoins conservée (valeur positive et inférieure à $\theta_{S,Min}$). Sur le site de Fontblanche (voir figure 6.2 (c) et (d)), l'erreur in situ ΔEF pour $\theta_S \approx \theta_{S,Min}$ (supérieure à 0.3 pour la Calibration Site sur le JdD Complet et le JdD Très Sec) permet d'affirmer que le facteur au premier ordre de l'erreur d'estimation de EF n'est pas l'effet des ombres portées. L'hypothèse selon laquelle l'erreur serait négligeable pour θ_S minimum n'est pas valable pour ce site. Ainsi, l'analyse de l'effet des ombres portées n'est pas poursuivie pour ce site.

La figure 6.3 montre les espaces 1- EF_{sat} vs θ_S utilisés pour la calibration du paramètre a_{auto} pour les jeux de données JdD Complet et JdD Très Sec sur le site Eddy Covariance de Puechabon. Les coefficients sont respectivement $a_{auto} = -0.0067$ et $a_{auto} = -0.010$ pour le JdD Complet et le JdD Très Sec. Ces valeurs sont rangées dans le même ordre que dans l'article ($a_{auto} = -0.005$ et $a_{auto} = -0.013$ pour le JdD Complet et le JdD Très Sec respectivement). La sensibilité de la méthode de détermination du bord

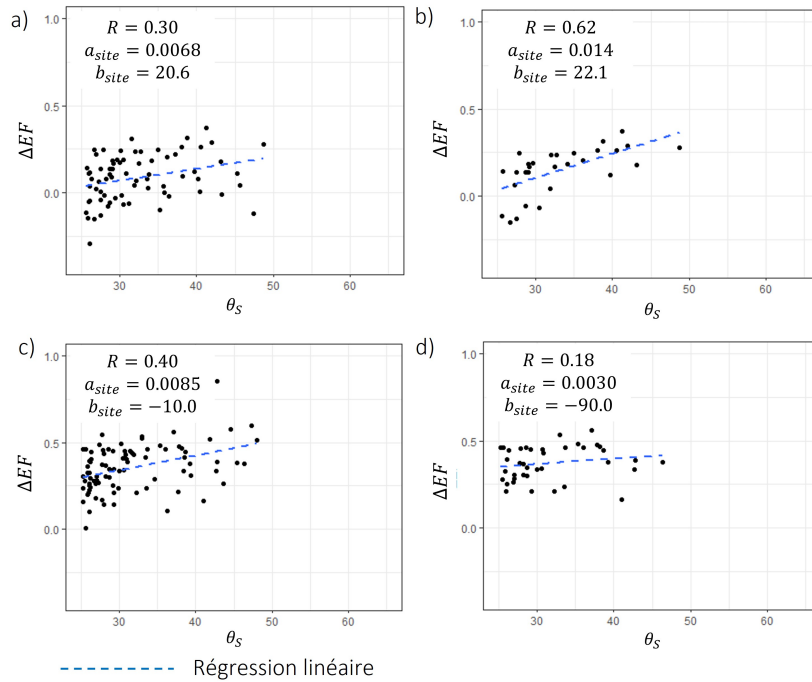


FIGURE 6.2 – Erreur in situ $\Delta EF = EF_{sat} - EF_{insitu}$ vs θ_S pour les sites de Puechabon (haut) et Fontblanche (bas), et pour le JdD Complet (gauche) et le JdD Très Sec (droite).

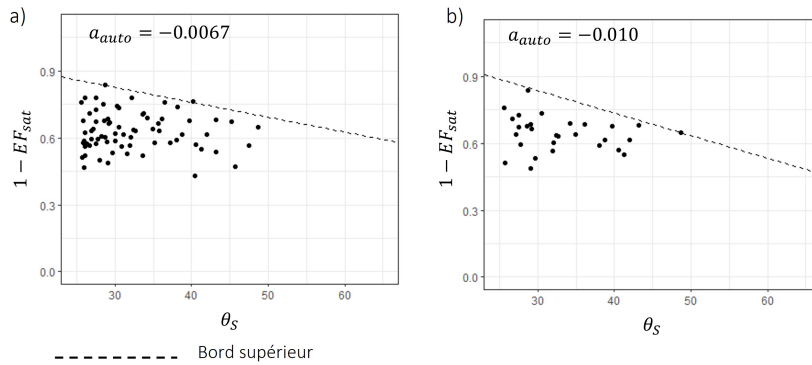


FIGURE 6.3 – Auto-Calibration du paramètre de correction a_{auto} sur le JdD Complet (a) et le JdD Très Sec (b) pour le site de Puechabon

supérieur qui dépend uniquement des points extrêmes pourrait expliquer la différence entre les résultats de l'article et ceux obtenus ici, alors que le jeu de données intègre une plus grande variabilité de conditions météorologiques et de surface dans l'aire d'étude.

Résultats et discussion des corrections

La figure 6.4 (a) présente le nuage de points de EF_{sat} (pas de correction) vs EF_{insitu} pour le site Eddy Covariance de Puechabon. La corrélation est faible ($R = 0.33$) de même que la sensibilité (pente=0.21). EF est principalement surestimée pour le JdD Sec alors que EF semble être bien estimée pour le JdD Humide. La figure 6.4 (b) présente le nuage de points de $EF_{c,site}$ dont la correction a été calibrée sur le JdD Complet. La corrélation est améliorée ($R = 0.42$) et en partie la pente (pente=0.28). EF pour le JdD Sec semble être mieux estimée alors que EF pour le JdD Humide semble être légèrement sur-corrigée. Un

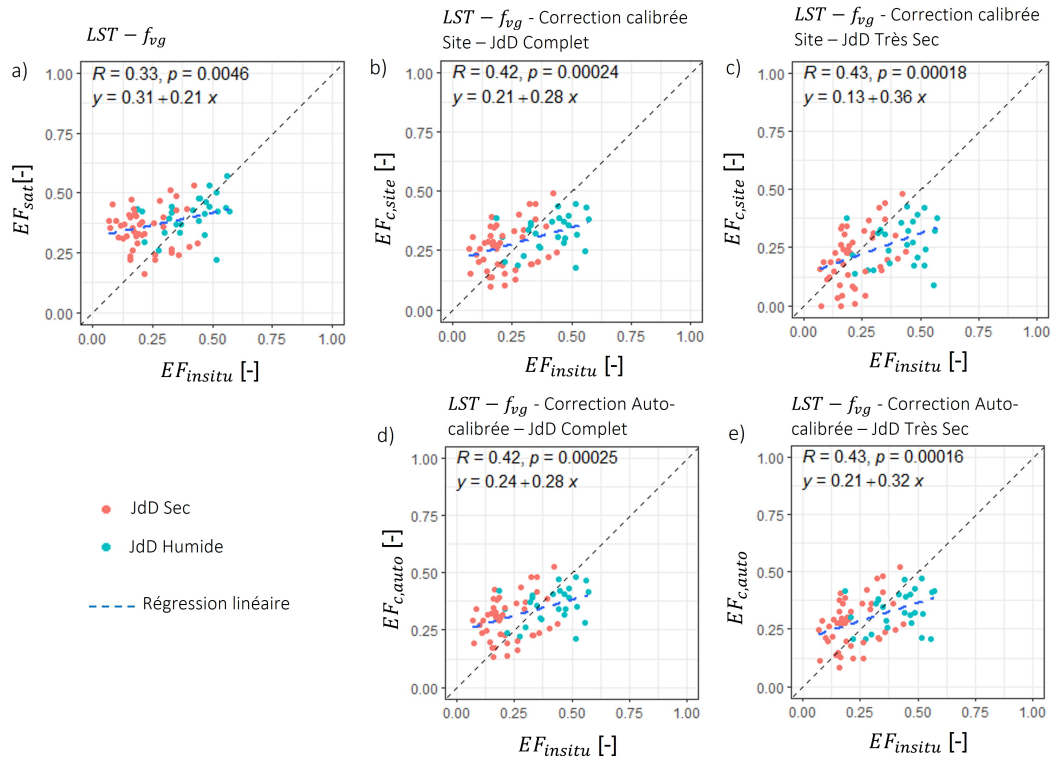


FIGURE 6.4 – Nuages de points des estimations et corrections de EF vs EF_{insitu} pour le site de Puechabon : pas de correction (a), $EF_{c,site}$ avec une calibration sur le JdD Complet (b), $EF_{c,site}$ avec une calibration sur le JdD Très Sec (c), $EF_{c,auto}$ avec une calibration sur le JdD Complet (d), $EF_{c,auto}$ avec une calibration sur le JdD Très Sec (e).

résultat similaire est obtenu en figure 6.4 (c) qui présente le nuage de points de $EF_{c,site}$ dont la correction a été calibrée sur le JdD Très Sec. Bien que la correction ne soit pas meilleure que précédemment ($R=0.43$), la pente est nettement améliorée (pente=0.36). Ce résultat semble être en partie dû à une bonne correction de EF pour le JdD Sec. Une sur-correction plus prononcée que précédemment de EF pour le JdD Humide est visible. Les Figures 6.4 (d) et (e) présentent respectivement les nuages de points de la Correction Auto-calibrée sur les JdD Complet et JdD Très Sec. Les résultats et les conclusions sont similaires à celles écrites pour la Correction calibrée Site, à savoir une correction intéressante pour le JdD Sec et un léger sur-correction pour le JdD Humide.

L'ensemble de ces résultats est analysé dans le Tableau 6.1 qui donne les métriques de précision par type de calibration (Calibration Site/Auto-Calibration) et jeu de calibration (JdD Complet/JdD Très Sec). Quelle que soit la méthode de calibration et le jeu de calibration, les corrections réduisent le biais absolu d'un facteur au moins 2.5 et l'erreur quadratique moyenne ($RMSE$) est aussi légèrement réduite. La Correction calibrée Site et la Correction Auto-calibrée permettent une augmentation de la corrélation et de la pente de la relation linéaire entre les corrections de EF_{sat} et EF_{insitu} . En particulier, les résultats issus des deux jeux de données de calibration (JdD Complet et JdD Très Sec) ne sont pas aussi différents ici que dans l'article, dans lequel le JdD Très Sec permettait des corrections plus qualitatives que le JdD Complet. Les moins bonnes performances des corrections entre cette étude et l'article pour la Correction calibrée Site et la Correction Auto-calibrée sur le JdD Très Sec pourraient s'expliquer par la plus grande variabilité des conditions météorologiques et de surfaces prises en compte.

Le Tableau 6.2 est identique au précédent mais présente les métriques de précision par jeu d'évaluation

Méthode de correction	Jeu de calibration	$RMSE$	biais	pente	R
Pas de correction	Complet	0.16	0.13	0.21	0.33
calibrée Site	Complet	0.13	0.00	0.28	0.42
calibrée Site	Très Sec	0.15	-0.05	0.36	0.43
Auto-calibrée	Complet	0.13	0.04	0.28	0.42
Auto-calibrée	Très Sec	0.13	0.01	0.32	0.43

TABLE 6.1 – Métriques de précision de l'estimation de EF vs EF_{insitu} par type de correction et jeu de données de calibration pour le site de Puechabon

(JdD Sec/JdD Humide). Les JdD Sec et JdD Humide comportent respectivement 48 et 27 passages de satellite pour Puechabon. Sur le JdD Sec, EF est surestimée sans correction (biais=0.13). EF_{sat} ne montre pas de sensibilité (pente=0.04) et une très faible corrélation ($R=0.05$) avec EF_{insitu} . Quelle que soit la correction (Correction calibrée Site/Correction Auto-calibrée sur JdD Complet/JdD Très Sec), elle permet une amélioration significative de la qualité de l'estimation de EF , en particulier une augmentation de la corrélation R (entre 0.30 et 0.46) et une diminution du biais (entre -0.01 et 0.08). Que ce soit avec la Correction calibrée Site ou la Correction Auto-calibrée, les estimations corrigées de EF sont meilleures si le jeu de calibration est le JdD Très Sec par rapport au JdD Complet : la corrélation R est supérieure ($R=0.46 / 0.39$ (Correction calibrée Site/ Correction Auto-calibrée) et $R=0.30 / 0.30$ pour le JdD Très Sec et JdD Complet respectivement), la $RMSE$ est plus faible (0.11 / 0.10 et 0.12 / 0.14), le biais est plus faible en valeur absolue (-0.01 / 0.06 et 0.05 / 0.08) et la pente plus proche de 1 (0.56 / 0.42 et 0.30 / 0.30). Ces résultats sont en accords avec ceux évalués sur le JdD Sec dans l'article et la calibration sur le JdD Très Sec ($R=0.59 / 0.48$, biais=0.00 / 0.05 et pente=0.84 / 0.59 pour la Correction calibrée Site et la Correction Auto-calibrée respectivement). Ces résultats confirment tout d'abord que la correction de l'effet des ombres portées est performante sur les conditions qualifiées de sèches, susceptibles d'être particulièrement affectées par l'effet des ombres portées. Ensuite, ces résultats démontrent que les corrections de l'effet des ombres portées fournissent de meilleures performances si elles sont calibrées sur le JdD Très Sec. A plus forte raison, la calibration sur le JdD Complet expose à la prise en compte de conditions où l'effet des ombres portées est négligeable (conditions humides) et de ce fait pourrait produire des valeurs de pentes trompeuses par rapport à l'objectif recherché de la correction.

Sur le JdD Humide, EF est estimée correctement sans correction (biais=0.00, $R=0.38$ et $RMSE=0.11$). Quelles que soient les corrections, elles sous-estiment EF pour le JdD Humide (sur-correction). Le biais (entre -0.13 et -0.04) et la $RMSE$ (entre 0.12 et 0.19) augmentent en valeur absolue et R (entre 0.17 et 0.31) diminue. Ces résultats sont en accord avec ceux de l'article, à savoir un effet de la correction des ombres portées sur le JdD Humide à questionner, en particulier du fait de l'augmentation du biais absolu. Ces résultats sont cohérents avec le fait que les conditions humides sont moins soumises aux effets des ombres portées (moindre contraste de LST entre partie à l'ombre et au soleil). Elles ne nécessiteraient pas de correction. Ces résultats permettent d'expliquer en partie les moins bonnes performances des corrections évaluées sur le JdD Complet par rapport à celles obtenues dans l'article.

6.2.3 Application opérationnelle de la méthode de correction de l'effet des ombres portées

La correction de l'effet des ombres portées (Correction Auto-calibrée) est mise en place sur 29 plaquettes du Réseau Hydrique (Martin-StPaul et al., 2018) entre 2015 et 2021. Les données météorologiques proviennent du jeu de réanalyse SAFRAN. Les zones d'étude sont de dimension 8x8 km centrées sur les plaquettes du Réseau Hydrique. La LST est corrigée des effets topographique conformément à Malbêteau et al.

Méthode de correction	Jeu d'évaluation	Jeu de calibration	$RMSE$	biais	penne	R
Pas de correction	Sec	Complet	0.18	0.13	0.04	0.05
calibrée Site	Sec	Complet	0.12	0.05	0.30	0.30
calibrée Site	Sec	Très Sec	0.11	-0.01	0.56	0.46
Auto-calibrée	Sec	Complet	0.14	0.08	0.30	0.30
Auto-calibrée	Sec	Très Sec	0.10	0.06	0.42	0.39
Pas de correction	Humide	Complet	0.11	0.00	0.26	0.38
calibrée Site	Humide	Complet	0.14	-0.08	0.20	0.31
calibrée Site	Humide	Très Sec	0.19	-0.13	0.14	0.17
Auto-calibrée	Humide	Complet	0.12	-0.04	0.20	0.31
Auto-calibrée	Humide	Très Sec	0.14	-0.07	0.17	0.24

TABLE 6.2 – Métriques de précision de l'estimation de EF vs EF_{insitu} par type de correction, jeu de données de calibration et jeu de données d'évaluation pour le site de Puechabon

(2017) par une chaîne de traitement automatisée¹. Le $LFMC$ mesuré sur les sites du Réseau Hydrique est interpolé linéairement dans le temps entre deux mesures et comparé à EF_{sat} et $EF_{c,auto}$. Les nuages de points globaux (figure A.1), par espèce (figure A.2) et par site (figure A.3) montrent que la corrélation est très faible mais significative. La correction des ombres portées ne solutionne pas la surestimation des faibles EF sur tous les sites, mais de manière générale elle apporte une légère amélioration.

La même méthode de correction de l'effet des ombres portées est appliquée pour la prédiction de la sévérité des incendies en suivant l'approche développée au Chapitre 3. La variable temporelle $EF_{c,auto}$ n'est pas sélectionnée lors de la phase de sélection des prédicteurs.

Dans les deux cas, un des problèmes identifiés est la difficulté à estimer la pente de correction a_{auto} dont la valeur est souvent nulle ou très faible. Cela remet en cause l'effet des ombres comme effet au premier ordre sur les erreurs d'estimation de EF .

6.2.4 Conclusion

Cette étude reprend les méthodes développées sur le site de Puechabon et présentées dans l'article disponible en Section 6.5. Des conditions météorologiques et de surface plus variées sont prises en compte pour tester la robustesse des conclusions de l'article. Les résultats pour le site de Puechabon, sont en accord avec ceux de l'article. Les conditions très sèches permettent d'inférer l'effet des ombres portées dont un proxy est le zénith solaire (augmentation de l'erreur sur EF avec le zénith solaire) dans un contexte où l'effet des ombres portées est supposé très important. Cet effet est aussi négligeable pour de valeurs de θ_S proche du nadir. Les conditions très sèches permettent aussi de calibrer deux corrections qualitatives de cet effet, dont une est opérationnelle. Ces corrections appliquées à l'ensemble du jeu de données, sont particulièrement performantes en conditions sèches et ne semblent pas nécessaires en conditions humides. Cependant, l'effet des ombres portées sur le site de Fontblanche n'explique pas l'erreur commise par l'approche contextuelle de référence $LST - f_{vg}$ au premier ordre. D'autres pistes sont à chercher pour ce site.

Ce complément d'étude permet aussi de suggérer des améliorations à l'Auto-Calibration proposée dans l'article (calibration opérationnelle). La détermination du bord supérieur de l'espace EF_{sat} vs θ_S pour l'Auto-Calibration est particulièrement sensible aux points extrêmes. Elle est donc peu robuste. Une autre approche devrait être mise en œuvre, qui s'appuie sur un plus grand nombre de points. Plutôt que d'utiliser le JdD Très Sec pour l'Auto-Calibration, le JdD Sec sur lequel l'effet des ombres est significatif, semble indiqué pour cette étape. Enfin, le JdD Humide ne devrait pas être corrigé de l'effet des ombres portées.

1. <https://gitlab.com/victor.penot/thermalstressindex2cor>

6.3 Combinaison de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ avec la correction de l'effet des ombres portées

Au Chapitre 5, la normalisation de la LST (LST_{norm}) des effets de hc associée à une détermination par un modèle bilan d'énergie (Tsd_{EB}) du bord sec plat de l'espace $LST_{norm} - f_{vg}$ ont permis de mieux estimer EF (réduction du biais absolu et augmentation de la corrélation pour les deux sites Eddy Covariance). Une partie de la réduction du biais absolu est à imputer à une sous-estimation de la température de sol nu sec observée par la température simulée par le modèle bilan d'énergie. Il serait plus cohérent de corriger ce biais en prenant en compte des effets propres à la forêt (eg effets directionnels). L'approche combinée $LST_{norm} - f_{vg}(Tsd_{EB})$ et correction de l'effet des ombres portées est développée par la suite pour surmonter cet obstacle. Les méthodes présentées dans le Chapitre 5 et dans la Section 6.2 sont mises en œuvre séquentiellement (approche $LST_{norm} - f_{vg}(Tsd_{EB})$ puis correction de EF_{sat} de l'effet des ombres portées) sur les sites de Puechabon et de Fontblanche.

6.3.1 Matériel et méthodes

L'ensemble du jeu de données présenté dans le Chapitre 5 est utilisé. Tout d'abord EF_{sat} est dérivée de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$, puis EF_{sat} est corrigée de l'effet des ombres portées (voir figure 6.5). Au regard des remarques sur les résultats du Chapitre 5 et de la Section 6.2, trois points méthodologiques évoluent. Dans le Chapitre 5, l'analyse de sensibilité a montré que G/Rn a principalement un effet sur le biais de EF_{sat} (augmentation du biais avec la diminution de G/Rn). Par ailleurs, la normalisation des effets de hc ne prend pas en compte les différences de G/Rn entre le sol nu et la végétation pleinement (cas des sites Eddy Covariance). Aussi dans l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ pour la normalisation effets de hc ($Hc_{max} = 43$ m), G/Rn est fixé à 0 (végétation pleinement couvrante, cas des deux sites Eddy Covariance) dans le modèle bilan d'énergie servant à simuler une température de sol nu sec (Tsd_{EB}). L'Auto-Calibration et la Calibration Site de la correction de l'effet des ombres portées s'effectuent sur le JdD Sec (avril à octobre). Une nouvelle méthode de détermination de a_{auto} est développée. L'intervalle $[\min(\theta_S), \max(\theta_S)]$ observé dans le JdD Sec est partitionné en intervalles de longueur 5° . Dans chaque intervalle non vide, le maximum de EF_{sat} et la médiane de θ_S dans l'intervalle sont obtenus. La pente a_{auto} est la pente de la régression linéaire des maxima de EF_{sat} sur les médianes de θ_S des intervalles. Enfin, seul le jeu de données sec (JdD Sec) est corrigé de l'effet des ombres portées.

6.3.2 Résultats et discussion

Les résultats issus des corrections calibrées sur le JdD Sec sont présentés pour les deux sites Eddy Covariance. Sauf mention contraire, la notation EF_{sat} traduit ici l'estimation de EF issue de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ (voir figure 6.5). Les JdD Sec et JdD Humide (avril à octobre) comportent respectivement 61/71 et 35/38 passages des satellites pour Puechabon/Fontblanche.

Résultats de la Correction calibrée Site et la Correction Auto-calibrée succédant à l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$

La figure 6.6 (a) et (c) présente la Calibration Site des coefficients de corrections à partir de EF_{sat} issue de la méthode $LST_{norm} - f_{vg}(Tsd_{EB})$. Pour les deux sites, la relation entre l'erreur in situ ΔEF et θ_S est significative bien que les corrélations soient assez faibles ($R = 0.44/0.37$ pour Puechabon/Fontblanche). a_{site} est positif (0.0097 et 0.0066 pour Puechabon et Fontblanche respectivement) donc l'erreur attribuée à l'effet des ombres portées est bien une fonction croissante de θ_S . Les valeurs de b_{site} (17.5° et 12.4° pour

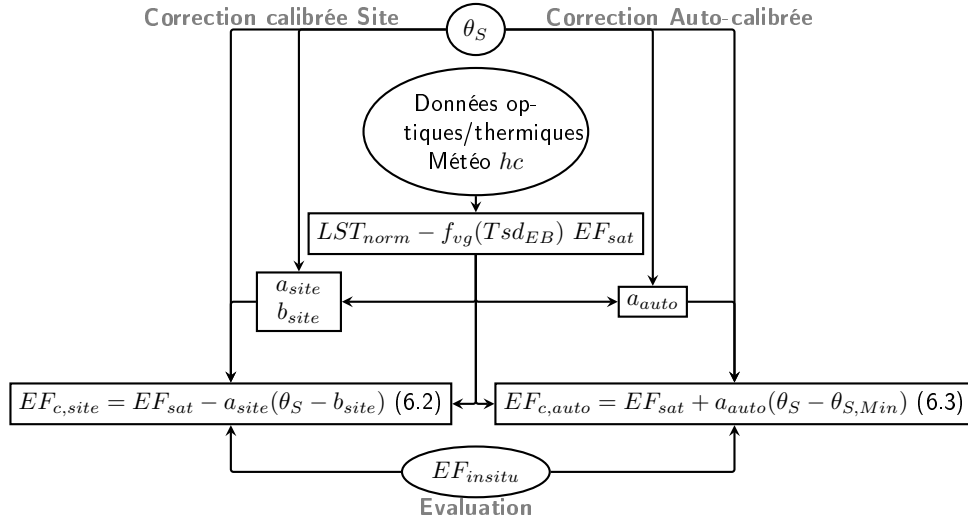


FIGURE 6.5 – Schéma de la méthodologie globale pour corriger EF_{sat} issue de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ de l'effet des ombres portées, pour calibrer cette correction à partir de données in situ (Correction calibrée Site, à gauche) ou de données de télédétection uniquement (Correction Auto-calibrée, à droite) et pour évaluer l'efficacité de la correction à partir des données in situ sur les sites Eddy Covariance (en bas).

Puechabon et Fontblanche respectivement) sont positives et inférieures à $\theta_{S,Min}$. Par ailleurs, sur les deux sites, l'erreur moyenne absolue in situ ΔEF est inférieure à 0.1 pour $\theta_S \approx \theta_{S,Min}$. L'erreur d'estimation de EF imputée à l'effet des ombres portées est bien négligeable pour θ_S proche du nadir. Il est cohérent que les valeurs de a_{site} et b_{site} diffèrent entre les deux sites car les géométries sub-pixellaires diffèrent. Sur le site de Puechabon, les effets des ombres portées semblent inférieurs à ceux mis en évidence dans la Section 6.2. Il est probable qu'une partie de l'erreur imputée à l'effet des ombres portées précédemment soient corrigée par l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$. Ces deux effets sont probablement du même ordre sur ce site. Sur le site de Fontblanche, où hc est plus importante qu'à Puechabon, l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ (effet du premier ordre) permet de mettre en évidence l'effet des ombres portées (effet du second ordre). L'effet des ombres portées semble avoir moins d'importance à Fontblanche qu'à Puechabon pour expliquer l'erreur d'estimation de EF . Ces résultats montrent la robustesse de l'hypothèse de l'effet des ombres portées, car l'utilisation d'un bord sec simulé par un modèle bilan d'énergie introduit une incertitude due au modèle et aux données dans l'estimation de EF par l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$.

La figure 6.6 ((b) et (d)) présente l'Auto-Calibration des coefficients de corrections à partir de EF_{sat} issue de la méthode $LST_{norm} - f_{vg}(Tsd_{EB})$. Les résultats de l'Auto-Calibration sont cohérents avec les résultats de la Calibration Site. Le bord supérieur de l'espace $1-EF_{sat}$ vs θ_S (voir figure 6.6 (b)), est bien défini et particulièrement décroissant pour le site de Puechabon ($a_{auto} = -0.021$). Sur le site de Fontblanche (voir figure 6.6 (d)), le bord supérieur reste bien défini. Il est moins décroissant ($a_{auto} = -0.011$) qu'à Puechabon, ce qui va dans le sens d'un moindre effet des ombres portées sur ce site.

Résultats de la Correction calibrée Site et de la Correction Auto-calibrée succédant à l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$

La figure 6.7 montre les nuages de points des différentes méthodes pour dériver EF des mesures satellitaires et des corrections des ombres portées pour les sites Eddy Covariance de Puechabon (haut) et Fontblanche (bas). Il n'existe pas un biais important sur EF issue de l'approche $LST - f_{vg}$ sur le site de Puechabon (biais=0.11, voir figure 6.7 (a)) mais la sensibilité (pente=0.18) et la corrélation ($R = 0.22$)

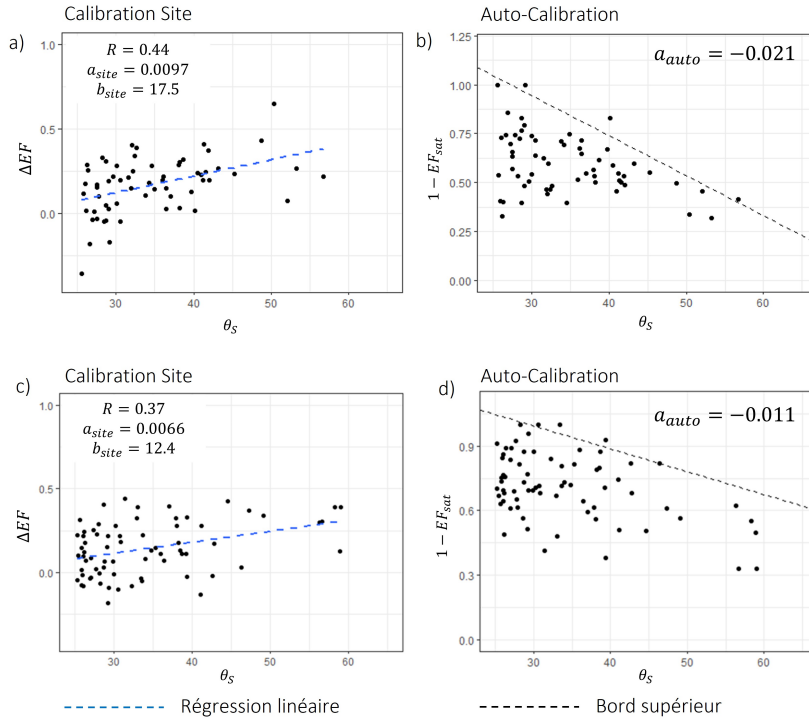


FIGURE 6.6 – Calibration Site et Auto-Calibration pour les sites de Puechabon ((a) et (b) respectivement) et de Fontblanche ((c) et (d) respectivement). Les Calibration Site et Auto-Calibration sont basées sur le JdD Sec et le EF_{sat} est issu de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$.

sont faibles. L'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ sur le site de Puechabon (voir figure 6.7 (b)) augmente la sensibilité (pente=0.40) et améliore la corrélation ($R = 0.36$) tout en surestimant EF (biais=0.14, comme anticipé en fixant le paramètre G/Rn à 0 dans le modèle bilan d'énergie servant à simuler Tsd_{EB}). Que ce soit pour la Correction calibrée Site que pour la Correction Auto-calibrée appliquée à EF_{sat} dérivée de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ (voir figure 6.7 (c) et (d) respectivement), les sensibilités (pente=0.77 et pente=0.87 respectivement) et les corrélations ($R = 0.58$ et $R = 0.58$ respectivement) sont largement augmentées alors que les biais sont réduits (biais=0.04 et biais=0.02 respectivement). Ces résultats sont confirmés sur le site de Fontblanche. La méthode $LST - f_{vg}$ ne produit pas une bonne estimation de EF (biais=0.36 et $R = 0.36$) (voir figure 6.7 (e)). Cette surestimation et le manque de sensibilité sont en grande partie corrigés par l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ ($R = 0.41$, biais=0.15) qui augmente la sensibilité (pente=0.58) comme anticipé dans le Chapitre 5 (voir figure 6.7 (f)). La Correction calibrée Site améliore la sensibilité et la corrélation de EF estimée ($R = 0.51$ et pente=0.80) (voir figure 6.7 (g)) tout en diminuant le biais (biais=0.06). Ce résultat confirme l'effet des ombres portées sur le site de Fontblanche. Cette amélioration est en partie conservée par la Correction Auto-calibrée (voir figure 6.7 (h)) car la sensibilité augmente (pente=0.70) de même que la corrélation ($R = 0.47$) et le biais reste relativement faible (biais=0.09). Sur les sites de Puéchabon et de Fontblanche, l'approche combinée $LST_{norm} - f_{vg}(Tsd_{EB})$ ($G/Rn = 0$) et correction de l'effet des ombres portées améliore l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ ($G/Rn = 0.32$) développée au Chapitre 5, notamment la corrélation et la pente.

En exemple d'application, les flux turbulents sont calculés pour les deux sites et les différentes méthodes d'estimation et de correction de EF (H_{site} et LE_{site} déduits de $EF_{c,site}$, H_{auto} et LE_{auto} déduits de $EF_{c,auto}$). Les résultats obtenus sur H et LE confirment les observations faites pour EF . La figure 6.8 présente les flux (H (haut) et LE (bas)) pour le site de Puéchabon. L'approche $LST - f_{vg}$ (Voir figure 6.8 (a) et (e)) sous-estime les hautes valeurs de H et les faibles valeurs de LE . Ces erreurs sont en partie

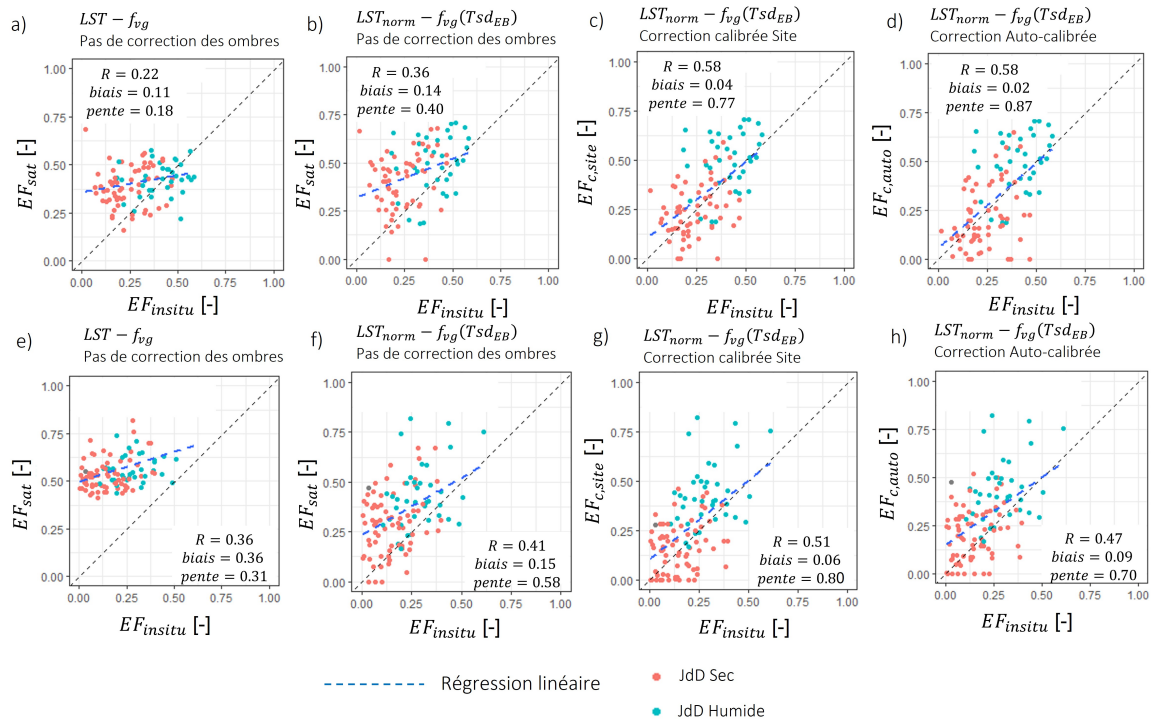


FIGURE 6.7 – Nuage de points des estimations et corrections de EF pour les sites de Puechabon (haut) et Fontblanche (bas) vs EF dérivée des mesures in situ. La première colonne ((a) et (e)) est l'estimation de EF par l'approche $LST - f_{vg}$, le deuxième colonne ((b) et (f)) par l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ ($G/Rn = 0$), la troisième colonne ((c) et (g)) par l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ suivie de la Correction calibrée Site et enfin la dernière colonne ((d) et (h)) par l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ suivie de la Correction Auto-calibrée.

corrigées par l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ (augmentation de la pente et de la corrélation, voir figure 6.8 (b) et (f)). L'approche combinée $LST_{norm} - f_{vg}(Tsd_{EB})$ et correction de l'effet des ombres portées permet une amélioration notable de l'estimation de H (biais=-45 / -67 $W.m^{-2}$ et $R = 0.69 / 0.65$ pour Correction calibrée Site/ Correction Auto-calibrée respectivement) mais surtout de LE (biais=10 / 33 $W.m^{-2}$ et $R = 0.62 / 0.58$) (Voir figure 6.8 (c), (d), (g) et (h)). Les résultats obtenus au Chapitre 5 avec l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ ($G/Rn = 0.32$) montraient des corrélations ($R = 0.62 / 0.41$ pour H / LE) et des sensibilités (pente=0.69 / 0.48) inférieures mais des biais absolus inférieurs (-31 / -4 $W.m^{-2}$).

Ces résultats sur H et LE sont aussi observables pour le site de Fontblanche (voir figure 6.9). L'approche $LST - f_{vg}$ produit des biais très importants avec une sur(sous) estimation de H (LE) (voir figure 6.9 (a) et (e)). L'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ permet de corriger la plus grande partie des erreurs avec une réduction par un facteur 2.1 et 2.5 du biais sur H et LE respectivement et une légère amélioration de la sensibilité (voir figure 6.9 (b) et (f)). L'approche combinée $LST_{norm} - f_{vg}(Tsd_{EB})$ et correction de l'effet des ombres portées (voir figure 6.9 (c), (d), (g) et (h)) permet principalement une diminution des biais absolus sur H et LE (biais=-62 / -92 $W.m^{-2}$ (H) et biais=34 / 65 $W.m^{-2}$ (LE) pour la Correction calibrée Site et la Correction Auto-calibrée respectivement). L'amélioration de la corrélation et de la sensibilité par rapport à l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ seule, est surtout notable pour LE ($R = 0.50 / 0.44$ et pente=0.78 / 0.65 pour la Correction calibrée Site et la Correction Auto-calibrée respectivement). Les résultats obtenus au Chapitre 5 avec l'utilisation de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ ($G/Rn = 0.32$) montraient une corrélation et une sensibilité moindre pour LE ($R = 0.34$ et pente=0.49),

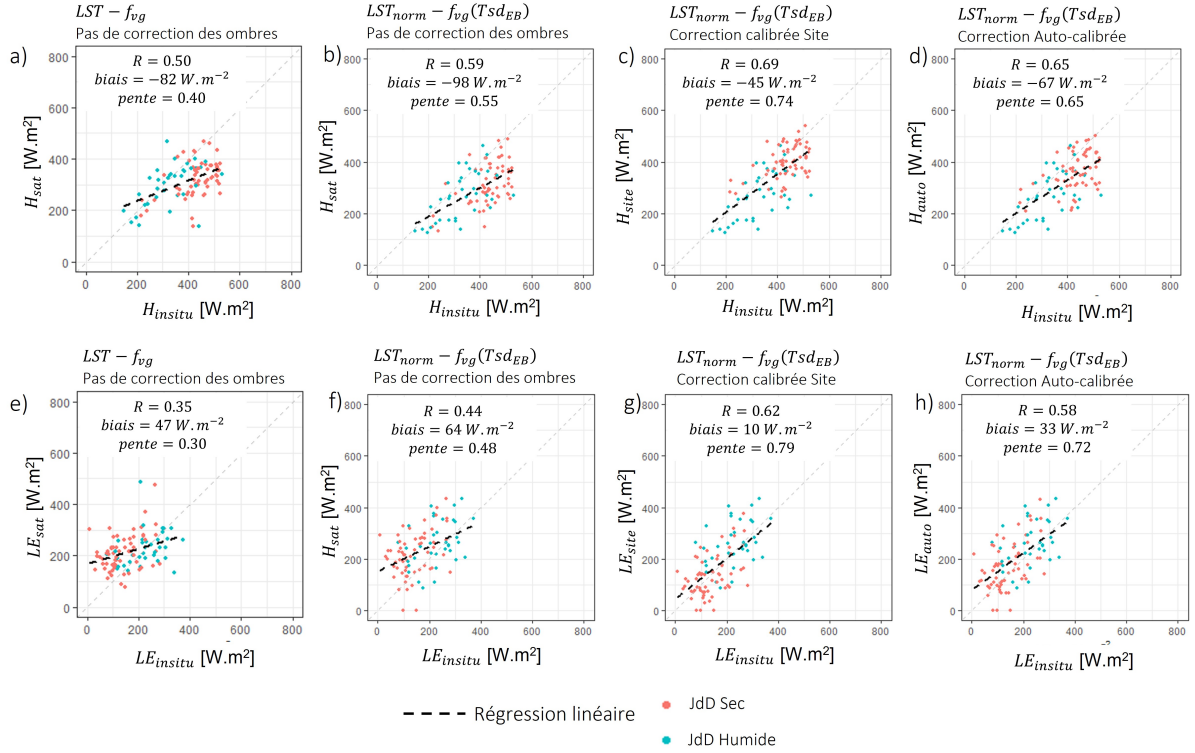


FIGURE 6.8 – Nuage de points des flux (H (haut) et LE (bas)) dérivés des différentes méthodes d'estimation et de correction de l'effet des ombres portées vs les flux dérivés des mesures in situ pour le site de Puechabon. La première colonne ((a) et (e)) est l'estimation des flux par l'approche $LST - f_{vg}$, le deuxième colonne ((b) et (f)) par l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ ($G/Rn = 0$), la troisième colonne ((c) et (g)) par l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ suivie de la Correction calibrée Site et enfin la dernière colonne ((d) et (h)) par l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ suivie de la Correction Auto-calibrée.

une corrélation similaire pour H ($R = 0.67$) et des biais absolus inférieurs pour les deux flux (-37 et 1 W.m^{-2} pour H et LE respectivement).

L'approche combinée $LST_{norm} - f_{vg}(Tsd_{EB})$ ($G/Rn = 0$) et correction de l'effet des ombres portées permet d'atteindre des résultats proches pour H , voir meilleurs pour LE , que l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ ($G/Rn = 0.32$) seule pour les deux sites en même temps. Elle est aussi plus cohérente physiquement. En effet, une partie du biais absolu sur EF , H et LE est réduit au Chapitre 5 par la sous-estimation de la température de sol nu sec observée par la température simulée par le modèle bilan d'énergie (biais de Tsd_{EB} ($G/Rn = 0.32$) par rapport à $Tsd_{context}$ de -5.5 K). Ce biais est désormais réduit grâce à la correction de l'effet des ombres portées (biais de Tsd_{EB} ($G/Rn = 0$) par rapport à $Tsd_{context}$ de -2.7 K), qui est un effet propre aux milieux tridimensionnels.

6.4 Conclusion

Les effets directionnels à la résolution spatiale des capteurs optiques des missions Landsat ou de la future mission spatiale TRISHNA sont limités aux effets des ombres portées. Dans ce Chapitre, il est montré que l'effet des ombres n'est pas un effet du premier ordre sur l'erreur d'estimation de EF issu de l'approche $LST - f_{vg}$ sur tous les sites Eddy Covariance. Cet effet est significatif et physiquement cohérent à Puechabon. Pourtant il n'explique pas les erreurs d'estimation de EF commises à Fontblanche. Sur le site de Puechabon, l'étude de l'erreur d'estimation de EF permet de confirmer que l'angle zénithal solaire

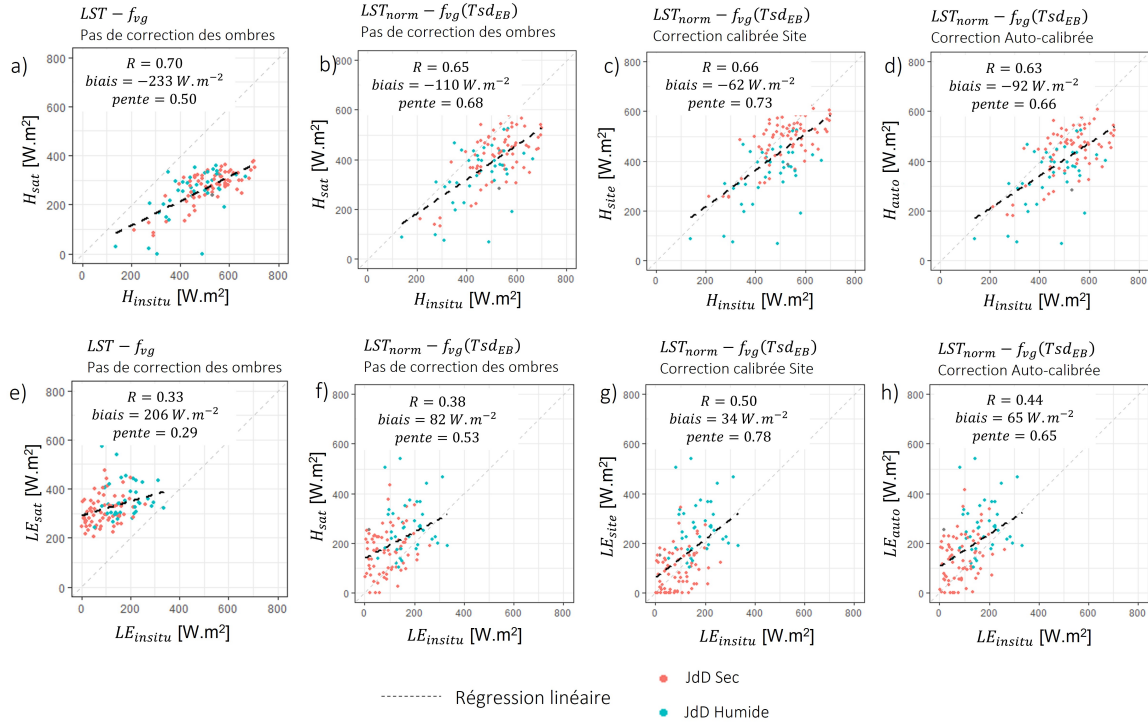


FIGURE 6.9 – Idem figure 6.8 mais pour le site de Fontblanche.

(θ_S) est un proxy de l'effet des ombres portées (augmentation de l'erreur d'estimation de EF avec θ_S) qui est négligeable pour θ_S proche du nadir. La prise en compte de cet effet en conditions très sèches permet de corriger efficacement et opérationnellement l'erreur d'estimation de EF sur ce site, particulièrement dans des conditions sèches. Ces résultats initialement décrits dans l'article joint à ce Chapitre sont amendés dans cette étude. En particulier, les conditions humides témoignent d'une estimation de EF par l'approche $LST - f_{vg}$ qui ne nécessite pas de correction des ombres portées.

Dans un deuxième temps, une combinaison de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ avec la correction de l'effet des ombres a été mise en oeuvre pour corriger l'erreur d'estimation de EF commise par l'approche $LST - f_{vg}$ sur les deux sites Eddy Covariance. L'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ prend en compte un effet du premier ordre sur l'erreur d'estimation de EF . Son application permet de mettre en évidence un effet du second ordre sur l'erreur d'estimation de EF – l'effet des ombres portées – sur les deux sites en même temps. L'utilisation combinée de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$ et correction de l'effet des ombres portées permet une meilleure correction de EF que l'une ou l'autre des deux méthodes appliquées séparément et pour les deux sites en même temps. Ces bons résultats se propagent à l'estimation des flux turbulents. Par ailleurs, cette application combinée permet de solutionner une limitation physique de l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$.

Malgré ces bons résultats, certains points restent à étudier. Tout d'abord, la valeur de b_{auto} (valeur de θ_S telle que l'effet des ombres est négligeable) qui est fixée à $\theta_{S,Min}$ observé sur la zone d'étude, reste à confirmer. En effet, avec EF estimée par la méthode $LST_{norm} - f_{vg}(Tsd_{EB})$, la Calibration Site de ce paramètre suggère des valeurs inférieures (environ 10-20°). A ce jour, ce paramètre ne peut être estimé qu'empiriquement. D'autres approches plus physiques devraient être développées pour l'estimer ou le calibrer avec plus de précision et de robustesse à l'échelle du pixel. Enfin, l'utilisation d'un bilan des pluies sur 15 jours pour discriminer les dates (très) sèches et humides est sans solution alternative. Étendre l'ensemble de ces études à d'autres sites et utiliser d'autres types de données pour la correction des ombres

portées (eg LiDAR) permettraient de rendre plus robuste les conclusions et d'inférer des solutions à ces limitations.

6.5 Article associé : "Estimating the water deficit index of a Mediterranean holm oak forest from landsat optical/thermal data : a phenomenological correction for trees casting shadow effects"

Estimating the Water Deficit Index of a Mediterranean Holm Oak Forest From Landsat Optical/Thermal Data: A Phenomenological Correction for Trees Casting Shadow Effects

Victor Penot  and Olivier Merlin 

Abstract—Land surface temperature (Ts) integrated in contextual evapotranspiration models can be used to derive the water stress level of forests. One difficulty of such models implemented over forests is related to the impact of trees casting shadows on the remotely sensed Ts, which potentially hide the water stress signature. Until now, there has been no method to correct for this effect at the spatial resolution of current (Landsat) thermal sensors. This study investigates the impact of the solar zenith angle as a proxy of trees casting shadows on the water deficit index (WDI), using Landsat-7 and Landsat-8 data over a 21-km² area partially covered by a holm oak forest in South-eastern France, for 7 successive summers (2015 to 2021). Results are compared to *in situ* evaporative fraction (EF) measurements. First, a calibration of the correction of WDI for shadow effects correlates the WDI error (WDI minus 1-EF) with the solar zenith angle. The correction improves the correlation (R) and slope between WDI and 1-EF, from R=0.32 to R=0.62 and slope=0.21 to slope=0.63, for non-corrected and corrected WDI respectively. Second, a calibration of the correction method that does not rely on *in situ* measurements, evaluates the linear relationship between remotely sensed WDI and the solar zenith angle in dry conditions. The correction improves the correlation and slope between WDI and 1-EF, from R=0.32 to R=0.57 and slope=0.21 to slope=0.50, for non-corrected and corrected WDI respectively.

Index Terms—Evapotranspiration (ET), forest, hydric stress, mediterranean ecosystems, thermal data.

I. INTRODUCTION

MEDITERRANEAN forests have dealt with high levels of hydric stress for long periods [1], [2]. However, global warming is a threat to most of forests all around the world [3], [4], [5] and particularly in the Mediterranean area, which is bound to be affected by increasingly frequent and severe droughts [6], [7]. Therefore, monitoring the hydric stress of Mediterranean forests is important in the context of climate change. It provides useful information for decision makers and landscape managers

Manuscript received 1 February 2023; revised 23 May 2023; accepted 14 June 2023. Date of publication 21 June 2023; date of current version 7 July 2023. This work was supported in part by the Horizon 2020 ACCWA project under Grant 823965 in the context of Marie Skłodowska-Curie research and innovation staff exchange (RISE) program. (Corresponding author: Victor Penot.)

The authors are with the Centre Etude Spatial de la BIOSphère, 31000 Toulouse, France (e-mail: victor.penot@iut-tlse3.fr; olivier.merlin1@univ-tlse3.fr).

Digital Object Identifier 10.1109/JSTARS.2023.3288360

to develop long-term forest/agricultural policies like the choice of species adapted to warmer and/or dryer conditions and mitigation management strategies [8], and also for firefighters to assess locally the short-term water dynamics of fuels [9], [10].

Remote sensing (RS) technology offers a good cost-benefit tradeoff to derive the evapotranspiration (ET) and water stress of ecosystems over wide areas on a daily/weekly basis. Different ET RS methods have been developed for this purpose and are generally based on optical/thermal data. There exists two broad categories: 1) the energy balance methods and 2) the contextual methods. The former are based on solving the physically based energy balance equations [11], [12]. They are generally more complicated to put into operational practice, due to their fine parametrization and their possibly large number of input parameters [13], [14]. The latter are based on semiempirical interpretations of the observed spatial correlations between land surface temperature (Ts) and fractional green vegetation cover (f_{vg}) [15], [16], [17] and/or albedo [18], [19] data. They may perform similarly to energy balance methods given a good calibration, whereas they are more parsimonious and hence simpler to apply over large areas [20], [21].

Under the assumptions of large gradients of surface hydric and vegetation cover states at the pixel scale and uniform meteorological conditions over the study area, the scatter plot of Ts versus f_{vg} , often called Ts- f_{vg} space, has the shape of a triangle or a trapezoid [15], [16]. The triangle method has, for instance, been used to assess the ability of Ts and f_{vg} to discriminate the vegetation moisture content of a Mediterranean forest in Spain [22]. The water deficit index (WDI), a proxy of surface water stress, is notably determined from the relative position of a point in the Ts- f_{vg} space [15], from a dry edge (fully dry pixels from bare soil to full canopy coverage) and a wet edge (well-watered pixels from bare soil to full canopy coverage). WDI has been widely used to assess the water stress of crops, and has shown good agreement with field measurements [15], [23], [24], [25]. However, to date, thermal RS methods have seldom been tested over Mediterranean forests. In an early study, Vidal and Devaux-Ros [26] used WDI as an index to predict the fire area/occurrence during the summer of 1990 in Southern France. However, the lack of site flux data in that study did not allow a quantitative assessment of the accuracy of the retrieved forest WDI.

Whatever thermal-based method is used to estimate the water stress, cast shadows within the canopy and on the ground have a strong influence on the measured T_s [27]. However, it is difficult to model and evaluate accurately the cast shadows impact in complex ecosystems [27]. The use of radiative transfer and/or geometric projection models supports these results, if a mock-up can be designed. The authors in [28], [29], [30], and [31] used these tools to study directional effects in oak woodlands or crops. They especially showed the strong impact of surface component fractions within the satellite field of view on T_s retrievals, and particularly through the contribution of shaded and sunlit soil.

To derive ET or water stress proxies in nonhomogeneous canopies, the authors in [32] and [33] suggested the use of data collected at very high resolution to explicitly take shadow effects into account. Three different methods have been developed from ground-based [33], [34], [35], [36] or aircraft/UAV-based [32], [37], [38], [39] thermal camera. One solution consists removing in the T_s image, the pixels corresponding to shaded soil/leaves to isolate sunlit leaves [32], [37], [38], [39]. It relies on the assumption that sunlit leaves are more likely to be stressed than shaded ones [40] and that they may provide meaningful information about the vegetation water status/flux. Separating shaded from sunlit soil/leaves requires a very high-resolution (centimetric) sensor. Such a classification can be done manually [35], [37], [39] or by automatic detection using supervised classification [39], [41], density-based methods [34], [36], [42], clustering (K-means) and postclassification [38], high resolution elevation thresholds [37], or vegetation index thresholds [32]. However, due to the geometric misregistration of visible/near-infrared and thermal images at such a fine resolution, soil and shaded leaves background may contaminate the thermal data of an area identified as sunny and vegetated [38], [42]. In addition, these methods rely mainly on a priori sunlit leaf properties, which are either physically determined or manually selected from images to build a training database. Therefore, the presence of mixed pixels or sunlit reflectances outside the training database may decrease the accuracy of the segmentation [41].

Another method to take shadow effects into account, consists in simply setting a ground-based camera in a position that avoids as much as possible shaded leaves/soil in the field of view of the thermal radiometer. The camera is hence generally set in a nadir/solar noon position so that only the sunlit part of the tree is observed without soil background [33], [34]. Note that this method strongly depends on the solar zenith angle and on the remaining ground and shaded leaves contamination [33], [34].

Rather than extracting sunlit leaves temperature from the thermal image or avoiding shadow effect in the sensor field of view, Luquet et al. [31] suggested a third option, that is to correct the WDI method to take into account directional effects. This correction involved redefining the wet and dry edges of the T_s - f_{vg} space by using a 3-D model that was run in each solar and observation angle. However this method uses realistic and efficient 3-D representation of every plant present within the study area. It requires both extensive and exhaustive ground measurements and a relatively small study area due to the high computation cost.

The above literature review indicates that until now no operational solution has been proposed to correct the remotely sensed water stress proxies for the cast shadow/directional effects at the scale of current (Landsat and MODIS/Sentinel-3) spaceborne thermal sensors. This is also true for near-future thermal missions which will provide T_s data at 57- and 50-m spatial resolution from 2025 and 2028 for TRISHNA and LSTM, respectively. In this context, the objective of this study is to propose an operational method for correcting the satellite-derived WDI for trees casting shadow effects, by relying on the solar zenith angle (θ_S). Specifically, this article aims at 1) quantitatively assessing the impact of θ_S on WDI and 2) developing a self-calibration correction of cast shadow effects.

To reach these goals, the study focuses on a common holm oak forest at Puechabon site, in Southern France, where in situ flux measurements are available between 2015 and 2021. Section II describes the study area, the in situ and Landsat data used and the new method to correct the Landsat-derived WDI for cast shadow effects. Section III presents the results obtained by calibrating the correction method using in situ data (site calibration) or satellite data solely (self-calibration) and discusses them in the prospect of future regional applications. Finally, Section IV concludes this article.

II. MATERIAL AND METHODS

A. Puechabon Site and in situ Data

1) *Puechabon Site*: The Puechabon site ($43^\circ 44' 29''\text{N}; 3^\circ 35' 46''\text{E}$, 270 m a.s.l.) is located in Southern France, 35-km north-west of Montpellier [43]. This site is representative of Mediterranean evergreen broadleaf forests with dense coppice. The holm oak (*Quercus Ilex* L.) is the dominant tree species, with a mean tree height of 5.5 m. The understory is composed of sparse shrubs of 2-m height [2]. The site was built in 1984 to study Mediterranean ecosystems and specially the holm oaks response to climate change and to severe droughts [1], [43].

The mean annual temperature over the 2008–2021 period is 14.5°C . The mean annual precipitation (2008–2021) is 877 mm with strong intra annual variations. Summer is dry and hot, while heavy precipitations occur primarily in fall but also in spring. For illustration, Fig. 1 plots the monthly cumulative rain and the monthly mean air temperature between 2015 and 2021 at the Puechabon site. This region is subject to a cool and dry north-west wind, known as “Mistral.”

Table I summarizes intra and interannual differences of cumulative rain and air temperature during the 2015–2021 study period. Three particular groups of years can be highlighted. 2015 was a particularly wet year during summer: it observed 267-mm cumulative rain between June and September, and 166-mm cumulative rain between July and August. 2017 was a particularly dry and hot year with only 74-mm cumulative rain between June and September, and 13-mm cumulative rain between July and August with five days over 35°C between June and September. 2016 also experienced a very dry summer (17 mm-cumulative rain between July and August), while 2018, 2019 and 2020 were hot years as regards the number of days above 30°C between June and September (38, 51, 41, respectively) and/or the number

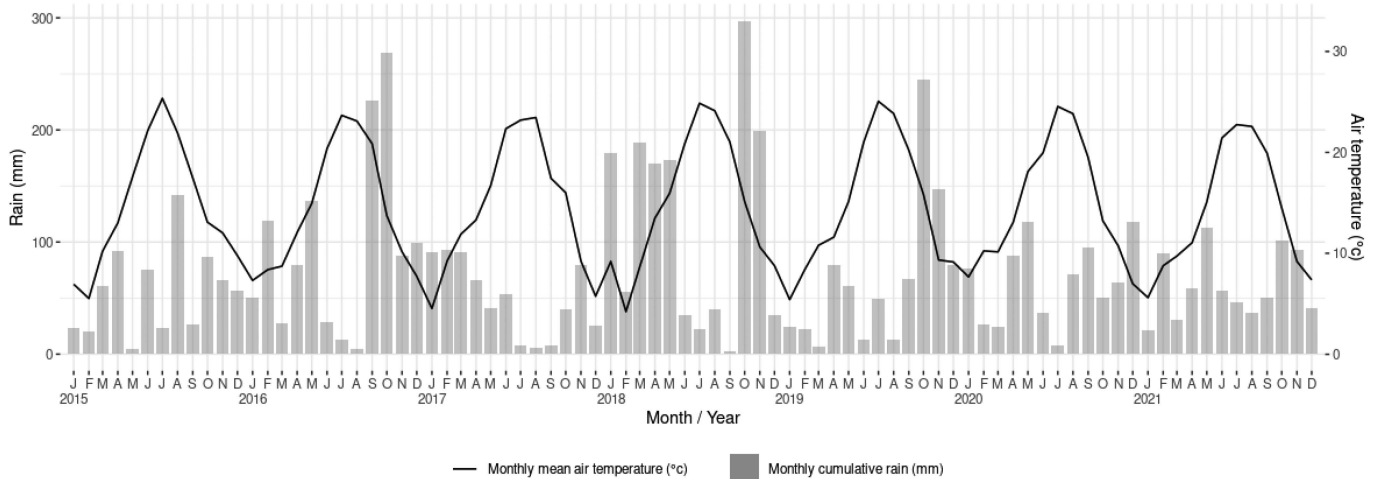


Fig. 1. Monthly cumulative rain and monthly mean temperature between 2015 and 2021 at the site of Puechabon.

TABLE I
SEASONAL CUMULATIVE RAIN AND THERMAL ANOMALIES FOR EACH YEAR SEPARATELY

Year	Cumulative rain February-May (mm)	Cumulative rain June-September (mm)	Cumulative rain July-August (mm)	Mean Tair June-September (°C)	Cumulative number of days Tair > 30°C June-September	Cumulative number of days Tair > 35°C June-September
2015	177	267	166	21.8	32	2
2016	363	271	17	22	34	0
2017	290	74	13	21.7	34	3
2018	588	98	62	22.8	38	5
2019	169	142	63	22.6	51	3
2020	256	211	79	22	41	1
2021	291	190	83	21.7	22	1

The all dataset is used for evaluation.

of days above 35 °C between June and September (5, 3, 1, respectively). It is important to note that in 2016, 2018, and 2019, the month of October was the rainiest of the year, suggesting that cloud cover during that month is likely to weaken the use of optical RS.

The soil at Puechabon site is silty clay loam with a rock and stone volumetric content of 75% in the first 50 cm and 90% in the whole profile [44]. It is poorly developed and does not store water well [2]. However, it was shown that *Quercus Illlex* was able to extract water deeper than 4 m during drought [44], [45].

2) *Flux and Meteorological Data*: The station of Puechabon is equipped with an eddy covariance flux measurement system that measures meteorological data and energy fluxes. The flux tower is 10-m height and equipped with a Sonic anemometer (Solent R3A Gill) and an infra red gas analyzer (IRGA, LI-6262, Li-COR) for latent and sensible heat flux measurements. The sampling is done at a rate of 21 Hz and recorded every 30 min. Allard et al. [45] studied the measurement footprint and its influence on the flux data in all weather conditions. It was shown that the measured fluxes come from a dense *Quercus Illlex* coppice, surrounded by a less dense *Quercus Illlex* dominated vegetation and that there is no seasonal pattern of footprint location. A temperature and humidity transmitter (MP100, Rotronic) is used for air temperature and rainfall measurement [45], [46]. Records are done every 30 min. Flux and meteorological data

from 2015 to 2021 were downloaded from the European Fluxes Database Cluster.

Regarding the monitoring and modeling of ET/hydric stress from thermal data, few studies have been undertaken at the Puechabon site. The authors in [47], [48], and [49] evaluated the 1-km resolution eight-day ET MODIS product. More recently, Ollivier et al. [2] developed an ET model driven by the MODIS EVI (enhanced vegetation index) for assessing the groundwater resource in the surrounding Karst watershed.

3) *Evaporative Fraction*: The evaporative fraction (EF) is defined as the ratio of latent heat to the available energy [16]

$$EF = \frac{LE}{R_n - G} \quad (1)$$

with LE being the latent heat (W/m²), R_n the net radiation (W/m²) and G the ground conduction (W/m²). G is not available at Puechabon site. So, under the assumption of energy balance closure, EF is expressed as

$$EF = \frac{LE}{LE + H} \quad (2)$$

with H being the sensible heat (W/m²). Allard et al. [45] showed that the energy closure (77%) at this site is reasonable and consistent with other similar sites.

The property of EF to remain constant during daytime hours [17], [50], [51] allows to check the quality of instantaneous EF estimates by means of the Bowen ratio β . The Bowen ratio is the ratio of the sum of H from 8 A.M. to 3 P.M. by the sum of LE from 8 A.M. to 3 P.M. [17]. Hence the daytime EF (EFd) can be estimated by means of the Bowen ratio

$$\text{EFd} = \frac{1}{1 + \beta}. \quad (3)$$

A statistical analysis during the study period shows a good agreement between instantaneous EF at 10:30 A.M. and the daily EFd ($R^2 = 0.89$, slope = 0.97). Hence the instantaneous EF is kept as a reference to evaluate the satellite-derived WDI. In practice, due to the inverse change direction of EF and WDI, the reference in situ hydric stress is estimated as 1-EF.

B. Remote Sensing Data and Study Area Extent

1) *Remote Sensing Data*: Landsat Enhanced Thematic Mapper Landsat-7 (ETM+) and Landsat-8 Operational Land Imager (OLI) and Thermal Infrared (TIR) both provide reflectance and Ts data with a 16-day revisit period, with an 8-day shift between Landsat-7 and Landsat-8. Landsat data for Path/Row 197/030 were downloaded from USGS Earth Explorer platform/Landsat Collection 2 Level-2 Science Products from 2015 to 2021. Shortwave optical data were corrected to be bottom of atmosphere reflectances and provided at their native resolution of 30 m. Landsat-7 data were processed with the landsat ecosystem disturbance adaptive processing system (LEDAPS) algorithm (Version 3.4.0) [52] and Landsat-8 data with the land surface reflectance code (LaSRC) algorithm (Version 1.5.0) [53].

After 2017, Landsat-7's orbit drifted from its original schedule to an earlier overpass time. Changes in reflectance and thermal data are limited until 2020 [54]. To ensure consistency between Landsat-7 and Landsat-8 data, we chose to keep only Landsat-7 acquisitions after 10:00 A.M. in the dataset.

f_{vg} is estimated using the expression of [55]

$$f_{vg} = \left(\frac{\text{NDVI} - \text{NDVI}_{\min}}{\text{NDVI}_{\max} - \text{NDVI}_{\min}} \right)^2 \quad (4)$$

with NDVI being the normalized difference vegetation index defined as the difference of near-infrared and red reflectances divided by their sum. $\text{NDVI}_{\min} = 0.19$ (bare soil) corresponds to the quantile 0.01 of NDVI over time (2015–2021) and space in the study area, and $\text{NDVI}_{\max} = 0.81$ (fully green vegetation cover) corresponds to the quantile 0.97 of NDVI over time (2015–2021) and space in the study area.

Landsat-7 and Landsat-8 thermal data have a native resolution of 60 and 100 m, respectively. Both datasets were downsampled at 30-m resolution and provided over the same 30-m resolution grid of Landsat reflectances. They were processed with the Landsat surface temperature algorithm (Version 1.3.0) to produce Ts maps from raw thermal radiances [56], [57].

2) *Study Area Extent and Description*: Contextual ET methods based on the Ts- f_{vg} space require the largest gradients of vegetation coverage and hydric state [58], [59]. Meteorological conditions must also be relatively homogeneous within the study area [14]. Thus the study area extent is defined to include the

Puechabon site and to observe the largest gradient of fraction cover, from bare soil (quarry and vineyard) to fully covering forests, and also the largest gradient of hydric state (from the Hérault river banks to bare dry soils), while minimizing the gradient of elevation. The 21-km² selected area is presented in Fig. 2. On its northern part, it is delimited by the narrow Hérault river and a plateau mainly covered by closed deciduous forests, where the flux site is set. Note that according to the data provider definition (Institut Géographique National, IGN), a closed canopy forest is covered by more than 40% of trees that reach a height of 5 m and more. Vineyards and some orchards (olive trees) occupy most of the Southern area. No town or major built area is included. The northern plateau and southern agricultural area are delimited by a topographic break [see Fig. 2(a) and (b)]. The minimum elevation of 40 m is reached in the southern part while the maximum elevation of 441 m is located in the northern part [see Fig. 2(b)]. Landsat RS data were thus extracted over this area for the whole time series.

C. WDI Method and Image Selection

The methodology to set the dry and wet edges of the Ts- f_{vg} space (Section II-C1 and II-C2) and to estimate the WDI (Section II-C3) is first presented. Then, a quality control of the input data is undertaken to automatically filter out the dates when meteorological conditions weaken the WDI application (Section II-C4).

1) *Dry Edge Estimation*: Dry conditions are generally encountered in the study area, due to the climatic context during late spring, summer, and early autumn. Therefore, the dry edge is defined as the linear regression of the 99% quantiles of Ts evaluated in equal-length f_{vg} bins against f_{vg} , as in [25] (see Fig. 3).

2) *Wet Edge Estimation*: Wet conditions are seldom met in the study area due to its climatic context. Hence, a physically based assumption must be set to solve this situation. The wet edge corresponds to pixels where LE is maximal and H minimal whatever f_{vg} . Thus when LE is maximal, H is negligible and can be set equal to 0 [17]. According to [60], Ts is approximately equal to aerodynamic temperature, so H is as a first guess proportional to the difference between Ts and air temperature (T_{air}) [15]. Following this reasoning, the wet edge in this study is set constant according to the equation $T_s = T_{air}(10:30)$ at the satellite overpass hour, i.e., 10:30 A.M. (see Fig. 3). This assumption has been successfully assessed in other previous studies undertaken in semiarid environments [19], [61], [62].

3) *WDI Calculation*: Fig. 3 illustrates how WDI is computed in the Ts- f_{vg} space from dry edge and wet edge distances [15]

$$\text{WDI} = \frac{BC}{AB} \quad (5)$$

with C being the point of interest, A the point in the dry edge line of same abscissa, and B the point of the wet edge line of same abscissa. By definition, WDI is the complement in 1 of EF, i.e., $\text{WDI} = 1 - \text{EF}$.

4) *Date Selection*: First, the use of thermal RS to evaluate hydric stress requires water-limited conditions meaning that Ts is driven mainly by water availability rather than by the energy available at the surface [14], [59]. Hence, the study period is

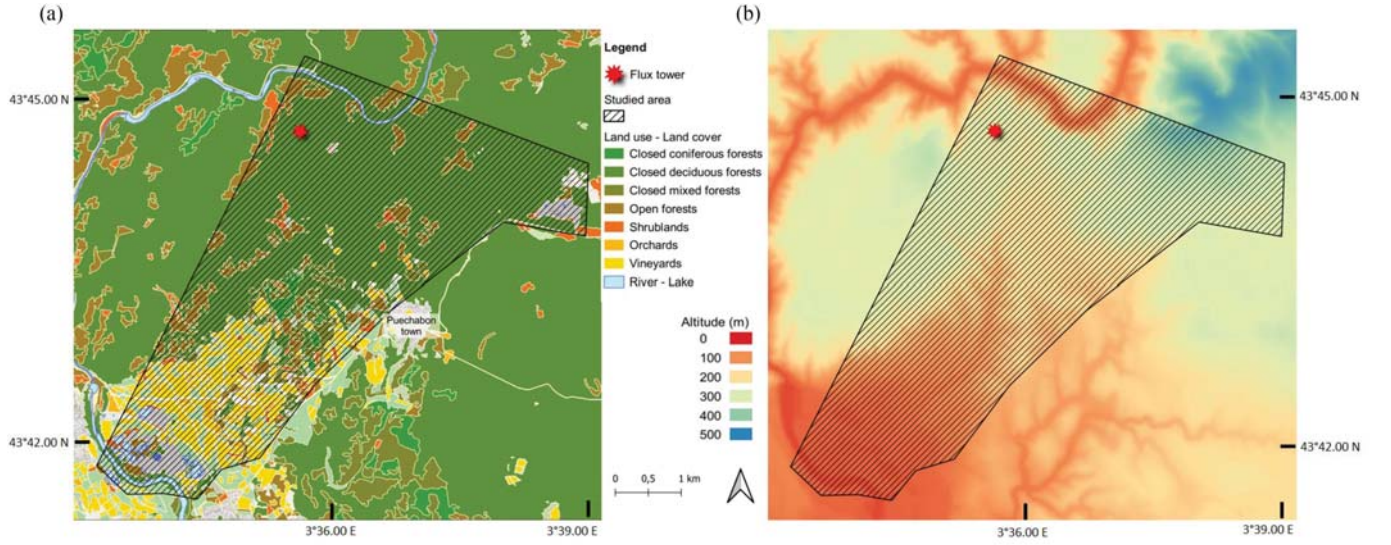


Fig. 2. (a) Land use and land cover map and (b) elevation map over the study area (Source : BDtopo and BDAlti of IGN).




Fig. 3. T_s - f_{vg} space and dry and wet edges plotted for Landsat-7 data collected over the study area on the 20th, August 2015.

defined to include the hottest months from May to September for each year from 2015 to 2021.

Second, the presence of clouds, cloud shadows, or recent rainfalls is likely to decrease T_s under the wet edge, defined as $T_{air}(10:30)$, as previously mentioned. Moreover, unstable/changing meteorological conditions may result in heterogeneous solar radiation, wind speed, and $T_{air}(10:30)$ within the area, which do not allow the use of contextual ET methods [14]. Therefore, an approach is proposed to automatically remove such dates. Only the pixels qualified as clear in the quality masks provided with Landsat-7/8 reflectance products are used during this filtering step. Zhang et al. [61] suggested that pixels with a T_s lower than $T_{air}(10:30)$ are contaminated by clouds or located over a water body. Accordingly, a date is removed from the dataset if $\min(T_s) \geq T_{air}(10:30) - 1$, considering that the image is contaminated by clouds. In addition, a minimum number of pixels within the image must be valid (qualified as clear in Landsat-7/8 masks) to get a representative view of all

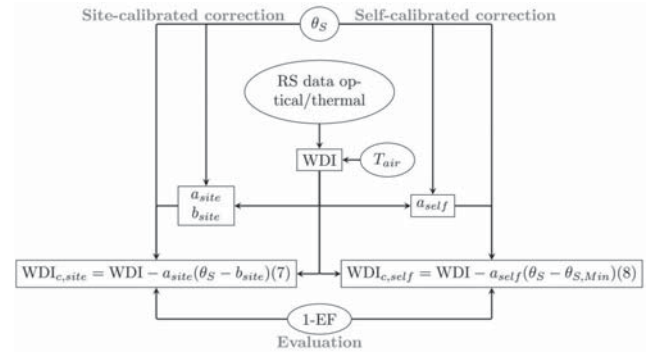


Fig. 4. Schematic diagram of the overall methodology to correct WDI for solar zenith angle effects, to calibrate this correction from in situ (site calibration, left) or from remote sensing (self-calibration, right) data solely and to evaluate the correction efficiency at the Puechabon site (bottom).

the required conditions in the study area. A threshold of 85% of clear pixels within the study area is chosen to filter out cloudy conditions. This limit quantifies the clear or low cloudy conditions that are commonly used in previous studies [15], [19], [63], [64].

D. Correction Method of WDI for Solar Zenith Angle

1) *General Approach:* The correction method proposed in this article relies on the assumption that cast shadows effects are strongly linked to solar zenith angle (θ_S) through cast shadow geometries, although this link is not explicit in complex geometries, such as tree canopies. For clarity, the framework of the correction strategies is summarized in the Fig. 4.

Once the WDI is classically estimated (as described in Section II-C3, see Fig. 4 upper part), a relation is built between WDI and θ_S

$$\Delta WDI = a(\theta_S - b) \quad (6)$$

with ΔWDI being the error on WDI attributed to cast shadows and a and b two empirical parameters. Two approaches are then proposed to calibrate a and b

- 1) if flux data are available, $(a_{\text{site}}, b_{\text{site}})$ is determined from the linear regression of $\Delta\text{WDI} = \text{WDI} - \text{EF} + 1$ with θ_S in particularly dry conditions. This correction strategy is called site-calibrated correction (see Fig. 4 left part);
- 2) if flux data are unavailable, which is the case in most operational situations, a_{self} can be estimated by interpreting the regression of WDI with θ_S in particularly dry conditions, and b_{self} is set to the minimum of θ_S in the May–September period, namely, $\theta_{S,\text{Min}}$. This correction strategy is called self-calibrated correction (see Fig. 4 right part).

For both correction strategies, ΔWDI is subtracted from WDI. Finally, the corrected WDI (WDI_c) is compared to in situ 1-EF (see Fig. 4 lower part) to evaluate the correction performance. Each component of the correction method is described as follows.

2) *Identification of Dry and Very Dry Conditions:* Hydric stress and shadow effects are generally mixed, and the main challenge herein is to disentangle both effects from WDI and θ_S data solely. Especially, the shadow effects on WDI may overwhelm the signature of hydric stress. During droughts, or during long periods without significant rains and high Tair, hydric stress grows to its maximum value, as long as trees and shrubs sustain the lack of water. In such extreme situations, the variations over time of WDI are assigned to variations of cast shadows geometry, which are mainly linked to θ_S . Hence, to disentangle cast shadow effects from hydric stress, only the driest dates of a time series should be used. We define the Very Dry dataset, as the dates of our dataset whose 15-day cumulative rain ($P_{15\text{d}}$) is under the first quartile of the 15-day cumulative rain of all days during the 2015–2021 study period ($q_{0.25}(P_{15\text{d}}) = 7\text{ mm}$). This dataset will be used for both site and self calibration strategies (see Section II-D3 and II-D4). The 15-day time depth is chosen on the basis of the regression quality of site calibration. We also define the Dry dataset (Wet dataset), as the dates of our dataset whose 15-day cumulative rain ($P_{15\text{d}}$) is under (over) the median of the 15-day cumulative rain of all days during the 2015–2021 study period ($q_{0.5}(P_{15\text{d}}) = 23\text{mm}$). These datasets will be used for evaluation purposes (see Section II-D5). The whole dataset is called All dataset.

3) *Site-Calibrated Correction:* When and where flux data are available, the difference between WDI and 1-EF regressed over θ_S can be used to correct the WDI [see (6)]. Only the Very Dry dataset is used for this regression. On such dates, the evolution of ΔWDI may be attributed to cast shadow effects rather than to hydric stress. This regression is useful to quantitatively assess the impact of θ_S on WDI at Puechabon site and to verify the underlying assumption of the correction methodology. The site-calibrated correction equation is

$$\text{WDI}_{c,\text{site}} = \text{WDI} - a_{\text{site}}(\theta_S - b_{\text{site}}). \quad (7)$$

4) *Self-Calibrated Correction:* In practice, flux data are rarely available and in general, they cannot be used for calibration purposes of (6) due to the strong heterogeneity of land surfaces. Therefore, a self-calibration method must be imagined

to operationally apply our proposed correction method, i.e., first by calibrating the slope a of (6) and then by setting the value of b .

A two-step procedure is proposed to isolate the dates when the WDI evolution is strongly influenced by cast shadow effects and to calibrate the slope $a = a_{\text{self}}$ of (6). First, only the Very Dry dataset is used, i.e., rainfall conditions when WDI is likely to be close to 1. Note that selecting the driest dates using the cumulative rain (instead of using large WDI values directly) allows for filtering out the dates when WDI is much affected by cast shadow effects. Then, WDI is plotted against θ_S and the upper edge of this space is linearly interpolated. The points located on the upper edge correspond to the pixels with an actual hydric stress index close to 1, so their WDI evolution with θ_S is assumed to be the result of cast shadow effects only. Hence the slope of the linear regression, called a_{self} quantitatively expresses the evolution of WDI with θ_S during droughts or very dry periods. While θ_S increases, cast shadow effect increases, so we expect that $a_{\text{self}} < 0$.

The intercept $b_{\text{self}} = b$ is set to the minimum of θ_S ($\theta_{S,\text{Min}}$) reached in late June at the site/pixel location. For a given canopy geometry, the impact of shaded areas at this time should be minimal when the Landsat viewing angle is near nadir [28], [29], which is the case in the Puechabon study area ($< 1.5^\circ$). Finally, we assume that the effect of θ_S on WDI is negligible when $\theta_S = \theta_{S,\text{Min}}$ and that it can only decrease WDI when θ_S increases. Therefore, the self-calibrated correction equation is

$$\text{WDI}_{c,\text{self}} = \text{WDI} - a_{\text{self}}(\theta_S - \theta_{S,\text{Min}}). \quad (8)$$

5) *Evaluation of Calibration and Correction Strategies:* To assess the quality and the improvements brought by both (site- and self-calibrated) corrections, the corrected WDI is evaluated against the site measurements of 1-EF for All dataset, Wet dataset, or Dry dataset separately. In each case, the root mean squared error (RMSE), mean absolute error (MAE), coefficient of correlation (R), slope and bias of the linear relationship between satellite WDI, and in situ 1-EF are calculated as metrics of quality and accuracy.

III. RESULTS AND DISCUSSION

To assess the impact of θ_S on WDI, Section III-A focuses on the results of the site-calibrated correction. In Section III-B, the results the self-calibrated correction are presented and discussed to assess the correction method in an operational context. In Section III-C, a spatial analysis of the self-calibrated correction method is proposed.

A. Site-Calibrated Correction of WDI for Solar Zenith Angle

1) *Site Calibration:* As mentioned previously, (1) is calibrated with the Very Dry dataset (including the 25% driest dates) with the objective of identifying the dates when θ_S significantly drives the error $\Delta\text{WDI} = (\text{WDI} - \text{EF} + 1)$. To assess the usefulness of this assumption, Fig. 5(a) and (b) plot the error ΔWDI versus θ_S for All dataset and Very Dry dataset, respectively. Table II summarizes the quality statistics of site-calibrated WDI

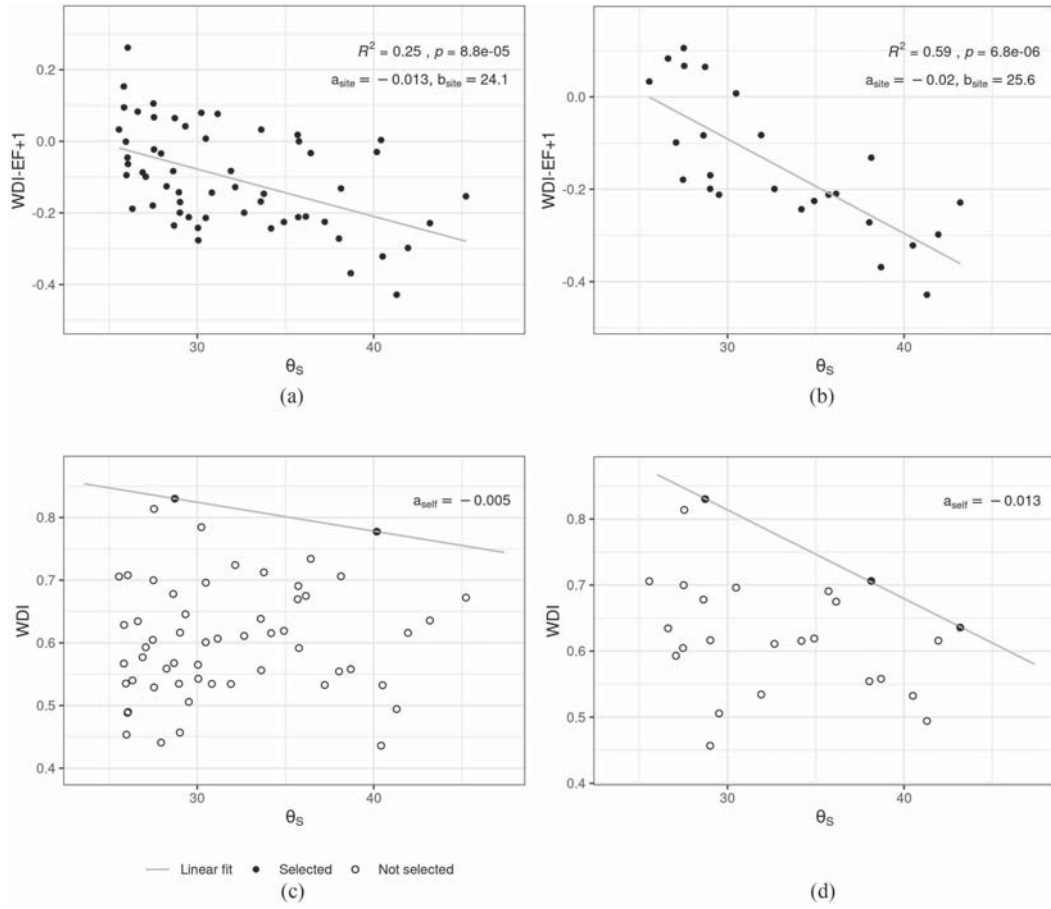


Fig. 5. Scatter plot from May to September during the years 2015–2021. (a) $(\theta_S, \text{WDI-EF+1})$ for the All dataset and the linear regression. (b) $(\theta_S, \text{WDI-EF+1})$ for the Very Dry dataset and the linear regression. (c) $(\theta_S, \text{WDI-EF+1})$ for All dataset and the linear upper hull. (d) (θ_S, WDI) for the Very Dry dataset and the linear upper hull.

TABLE II
STATISTICAL RESULTS IN TERMS OF MAE, RMSE, R, SLOPE AND BIAS OF THE LINEAR REGRESSION BETWEEN SATELLITE WDI AND IN SITU 1-EF FOR DIFFERENT CORRECTION AND CALIBRATION STRATEGIES

Correction method	Calibration dataset	MAE	RMSE	R	Slope	Bias
None	All	0.14	0.17	0.32	0.21	-0.10
Site	All	0.10	0.12	0.57	0.50	0.00
Site	Very Dry	0.10	0.12	0.62	0.63	0.02
Self	All	0.13	0.15	0.44	0.31	-0.07
Self	Very Dry	0.11	0.12	0.57	0.50	-0.02

The all dataset is used for evaluation.

when All dataset and Very Dry dataset is used for calibration separately. Fig. 6(a) and (b) plot the noncorrected and site-calibrated corrected WDI (using Very Dry dataset for calibration) versus 1-EF, respectively.

Both site calibration strategies improve the quality of the corrected WDI compared to the noncorrected WDI [see Table II and Fig. 6(a) and (b)]. The slope and correlation coefficient increases from 0.21 and 0.32 (no correction) to 0.50 and 0.57 for the All dataset and 0.63 and 0.62 for the Very Dry dataset used for calibration, respectively. The bias and RMSE also significantly decrease from bias = -0.10 and RMSE = 0.17 (no correction) to bias = 0.00 and RMSE = 0.12, and bias = 0.02 and RMSE = 0.12

for the All dataset and Very Dry dataset-based calibration corrections, respectively. Note that the RMSE remains in the standards of other studies in similar context [64], [65], [66].

Even if the calibration regression using All dataset is significant (determination coefficient $R^2 = 0.25$ and $p\text{value} < 5\%$), its quality is clearly improved when only the Very Dry dataset is used for calibration [$R^2 = 0.59$ and $p\text{value} < 5\%$, see Fig. 5(a) and (b)]. These results suggest that θ_S significantly drives the evolution of ΔWDI when only very dry conditions are encountered, i.e., when cast shadow effect is the main driver of WDI. In fact, when the actual hydric stress index is close to 1 and when the contrast between sunny and shaded areas is large, the impact of hydric stress on T_s is expected to be small compared to cast shadow effects. Based on the above analysis, the Very Dry dataset is henceforth used for calibrating the correction method.

The slope a_{site} in Fig. 5 is negative, which is consistent with the fact that the cast shadow effect on WDI increases with θ_S (initial assumption). The site calibration provides a correction slope $a_{\text{site}} = -0.020$ [see Fig. 5(b)] that quantifies the underestimation of 1-EF by WDI with the increase of θ_S across the seasons. It also provides an intercept $b_{\text{site}} = 25.6^\circ$ [see Fig. 5(b)] that is near the minimum solar zenith angle ($\theta_{S,\text{Min}} = 25.7^\circ$) reached in late June at the Puechabon site. This value implies that ΔWDI is




Fig. 6. Scatter plot. (a) Noncorrected WDI versus 1-EF. (b) $WDI_{c,site}$ versus 1-EF. (c) $WDI_{c,self}$ versus 1-EF. The Very Dry dataset is used for both site and self-calibration cases.

TABLE III
STATISTICAL RESULTS IN TERMS OF MAE, RMSE, R, SLOPE AND BIAS OF THE LINEAR REGRESSION BETWEEN SATELLITE WDI AND IN SITU 1-EF FOR DIFFERENT CORRECTION AND EVALUATION STRATEGIES

Correction method	Evaluation dataset	MAE	RMSE	R	Slope	Bias
None	Wet	0.09	0.11	0.21	0.14	-0.02
Site	Wet	0.10	0.14	0.36	0.37	0.08
Self	Wet	0.10	0.12	0.35	0.29	0.04
None	Dry	0.17	0.20	0.08	0.07	-0.15
Site	Dry	0.10	0.11	0.59	0.84	0.00
Self	Dry	0.11	0.12	0.48	0.59	-0.05

negligible when θ_S is minimum and that ΔWDI becomes more and more negative when θ_S increases. This is consistent with a minimum cast shadow effect on T_s and hence on WDI in late June, while the Landsat viewing angle is near nadir ($< 1.5^\circ$) at the Puechabon site [28], [29].

In brief, the site calibration provides an equation that efficiently corrects for the cast shadow effects over the full θ_S range (from May to September). The value of the correction is null when θ_S is minimum in late June, it linearly increases with θ_S and reaches its maximum value in late September when θ_S is maximum.

2) *Evaluation of the Site-Calibrated Correction:* Table III summarizes the statistics obtained for different calibration strategies and evaluation datasets. The site-calibrated corrected WDI outperforms the noncorrected WDI when evaluated on the Dry dataset (37 dates). When evaluated on the Dry dataset, the correction improves the slope of the linear regression (and correlation coefficient) from 0.07 to 0.84 (from 0.08 to 0.59) for the noncorrected and site-calibrated corrected WDI, respectively. In parallel the bias decreases from -0.15 to 0.00 for noncorrected and site-calibrated corrected WDI, respectively. The good performance of the correction method for the Dry dataset is explained by strong cast shadow effects when the contrast between sunny areas and shaded areas is maximum.

However, the site-calibrated correction is not so successful when it is evaluated on the Wet dataset (20 dates). Even if R

and slope still increase from $R=0.21/slope=0.14$ (no correction) to $R = 0.36/slope = 0.37$ (site calibrated correction), the bias significantly increases from bias = -0.02 (no correction) to bias = 0.08 (site-calibrated correction) (see Table III). These results support the fact that wet dates/areas are less likely to be affected by shadow effects. Consequently, a correction equation that is calibrated over Very Dry dataset tends to overcorrect WDI for the Wet dataset.

Note that the land-atmosphere feedback on air temperature [67] was neglected in this study. Especially, due to the general absence of wet conditions in the study area, the wet edge was set to a constant value based on the equation $T_s=T_{air}$ (measured at Puechabon site at 10:30 A.M.), regardless of the stress level of the underlying surface. This strategy is likely to overestimate the temperature of the wet edge and hence to underestimate the satellite-derived stress index in dry conditions. Disentangling both (feedback on air temperature and trees casting shadow) effects on the satellite-derived stress index should be investigated in the future.

3) *Yearly Analysis of Site-Calibrated Correction Results:* Fig. 7(a) and (b) plots noncorrected and site-calibrated corrected WDI versus 1-EF per year. The correction not only improves the 1-EF estimation over the whole study period but also for almost every year separately (2016, 2017, 2018, 2019, 2020, 2021) but 2015.

2015 is a particularly wet year that illustrates the limitation of the correction methods: the proposed correction for trees casting shadow effects does not bring any improvement to the classical WDI without correction [see Fig. 7(a) and (b)]. The slope decreases from 0.30 to 0.23 and the correlation coefficient from 0.53 to 0.28 for noncorrected WDI and site-calibrated corrected WDI, respectively. Particularly, the correction for the Wet dataset tends to overcorrect WDI. This year is the rainiest of the seven studied years during summer, with 267-mm cumulative rain between June and September, after the driest beginning of year (177 mm of cumulative rain between February and May). Locally, Limousin et al. [1] actually measured in 2015 the maximum of minimum predawn summer water potentials—a

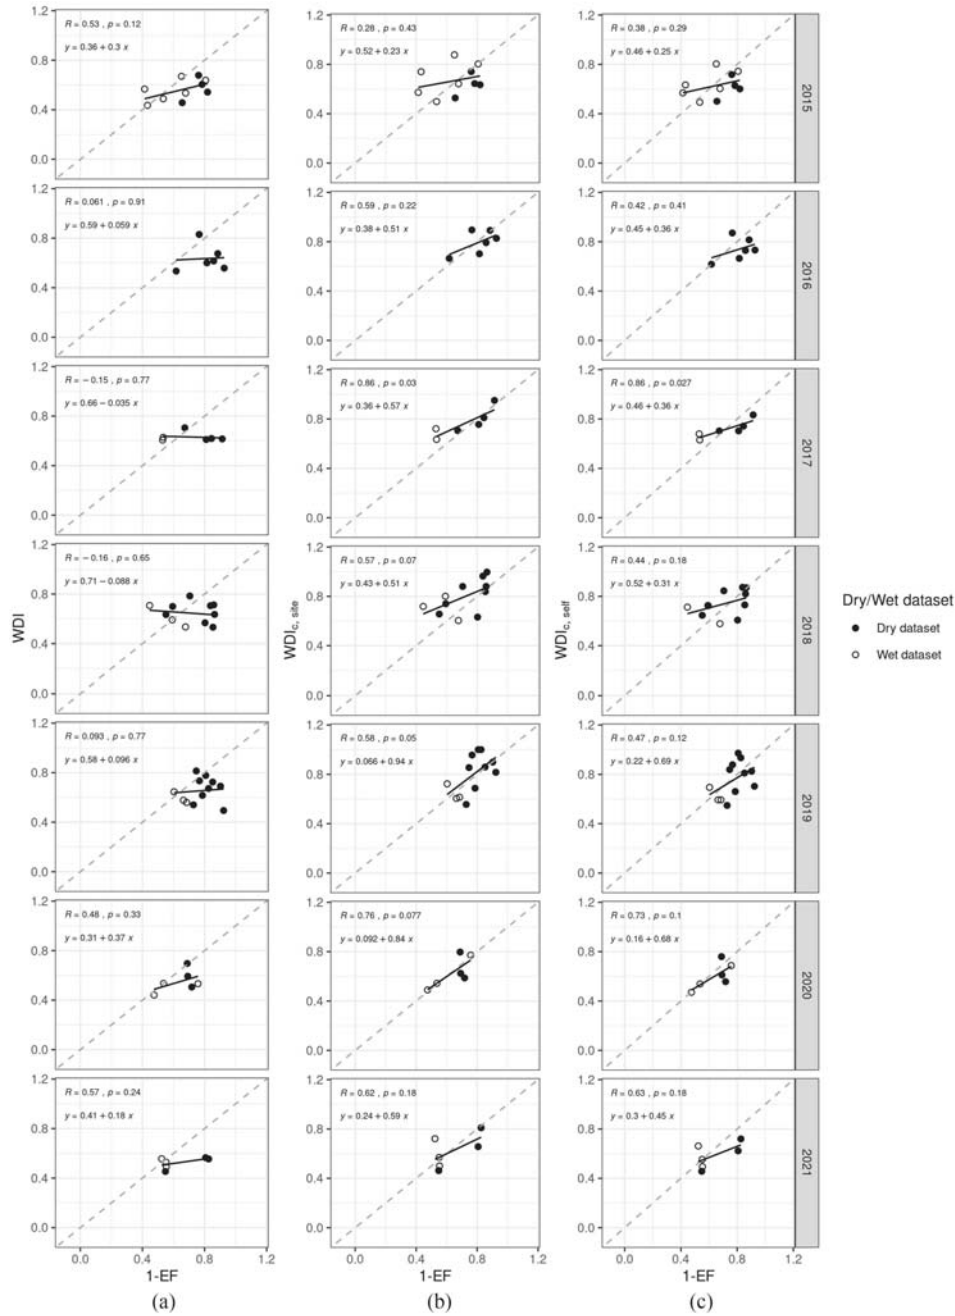


Fig. 7. Per year scatter plot. (a) Noncorrected WDI versus 1-EF. (b) $WDI_{c,site}$ versus 1-EF. (c) $WDI_{c,self}$ versus 1-EF.

proxy of plant and soil water limitation [44]—and the rainiest summer (June–August) over the 2003–2017 summers.

These results suggest that when water is available, cast shadows is not the main driver of WDI variations. However, the relatively small number (6–12) of observations available for each year separately, does not allow a deeper evaluation of the correction method on an interannual basis.

B. Self-Calibrated Correction of WDI for Solar Zenith Angle

1) *Self-Calibration Equation*: For operational needs, a self-calibrated correction method is developed by plotting WDI

versus θ_S , without relying on flux data. The calibration of the slope a_{self} of (6) is undertaken using both the All dataset and the Very Dry dataset separately to assess the performance of each calibration strategy. As for the site calibration case, selecting the Very Dry dataset allows to better identify the impact of cast shadow effects. Therefore, the calibration of a_{self} using the Very Dry dataset provides a more efficient correction than when it is calibrated with the All dataset. In Table II, we see that with the All dataset, the slope (and R) only increases from slope = 0.21 (0.32) to 0.31 (0.44) for the noncorrected and self-calibrated corrected WDI, respectively. In contrast, using the Very Dry dataset the slope (and R) significantly increases from 0.21 (0.32)

to 0.50 (0.57) for the noncorrected and self-calibrated corrected WDI, respectively. In parallel the bias decreases (in absolute value) from -0.10 (no correction) to -0.07 (All dataset-based calibration correction) and to -0.02 (Very Dry dataset-based calibration correction). These results suggest that isolating particularly dry conditions during the calibration step allows to get a more efficient correction on WDI [see Fig. 5(c) and (d)], and are consistent with the same analysis undertaken for the site calibration. We now consider the WDI correction results obtained from the calibration of a_{self} using the Very Dry dataset only.

The negative value of the slope $a_{\text{self}} = -0.013$ is consistent with the increase of cast shadow effects with θ_S , as already mentioned for the site-calibrated correction case [see Fig. 5(b) and (d)]. Even if a_{self} is lower (in absolute value) than a_{site} , the previous discussion in Section III-A1 remains valid.

Only seven years of data have been used for the self-calibration, meaning that the calibration strategy is likely to be sensitive to outliers. Even if this dataset covers a wide range of meteorological conditions, including particularly wet (2015) and dry (2017) years, a longer calibration period is likely to provide more statistically significant results. In fact, the upper edge of the WDI- θ_S space is strongly influenced by extreme points that may be encountered during dry and hot years. In other words, drier conditions might change the calibrated value of the self-calibration slope a_{self} .

To define the final calibration (8), the intercept is set to the minimum θ_S between May and September— $b_{\text{self}} = \theta_{S,\text{Min}} = 25.7^\circ$ —which is close to the site-calibrated $b_{\text{site}} = 25.6^\circ$. It is suggested that cast shadow effects are negligible in mid-June, when the difference between the viewing zenith angle of Landsat (near nadir) and θ_S is minimum. Despite the good agreement between b_{site} and $\theta_{S,\text{Min}}$ at the Puechabon site, further researches should be conducted to assess the variability of b parameter in time and space.

2) *Evaluation of the Self-Calibrated Correction:* Results presented in Fig. 6 and Table III indicate that the self-calibrated corrected WDI outperforms the noncorrected WDI when evaluated on the Dry dataset. In particular, the self-calibrated correction improves the slope and correlation coefficient (see Table III), which increase from 0.07 to 0.59 and from 0.08 to 0.48, respectively. In parallel the bias decreases in absolute value from 0.15 to 0.05 for noncorrected and self-calibrated corrected WDI, respectively. However, the self-calibrated corrected WDI is not so successful when evaluated on the Wet dataset. Even though both R and slope are slightly improved from 0.21 to 0.35 and from 0.14 to 0.29, respectively, the absolute bias increases from 0.02 (no correction) to 0.04 (site-calibrated correction) (see Table III).

These results are fully consistent with those obtained for the site-calibrated correction case discussed previously. The behavior of the self-calibrated corrected WDI is very similar to that of the site-calibrated corrected WDI, as illustrated in the per year analysis of Fig. 7(a) and (c). Because $a_{\text{site}} < a_{\text{self}}$, the self-calibrated correction is slightly less effective to correct WDI for Dry dataset, and consequently limits the overcorrection of WDI for Wet dataset. The self- and site-calibrated corrections are generally of equivalent quality. This result confirms that the

slope of the linear upper edge of the WDI- θ_S space in particularly dry conditions (Very Dry dataset) is a good approximation of the a_{site} parameter in (8).

C. Spatial Analysis of the Self-Calibrated Correction

The self-calibrated correction of WDI for solar zenith angle has been assessed in terms of WDI accuracy at the Puechabon site. It is also interesting to investigate the spatial behavior of the corrected WDI and the correction parameters (a_{self}) at the pixel scale within the study area. The study area [see Fig. 2(a)] is characterized by a large variability of land use and land covers from bare soil, organized vineyards and orchards in the south, to wild Mediterranean evergreen forests in the north. To assess spatially the self-calibrated correction in such media, the method is applied at the 30-m resolution over the entire study area and during the entire study period (2015–2021). The satellite-derived WDI is smoothed with a 5×5 pixels split window to take into account the actual spatial resolution of thermal Landsat data (60 and 100 m for Landsat-7 and Landsat-8, respectively). θ_S is supposed to be uniform withinover the whole study area on each Landsat overpass. Note that for few pixels, the retrieved correction slope a_{self} is positive; in this case it is set to 0. The minimum θ_S is set to 25.7° at each pixel of the study area. The self-calibrated correction equation can finally be applied to correct WDI for cast shadow effects over the entire study area.

Fig. 8 shows maps and density histograms of WDI and $\text{WDI}_{c,\text{self}}$, respectively, for data on the 22th, July 2016. The summer 2016 is particularly dry and hot at the Puechabon Site. Cumulative rainfall during the 15 previous days is only 0.2 mm. The measured 1-EF at the flux site is 0.88, site-calibrated corrected $\text{WDI}_{c,\text{self}}$ is 0.81 while noncorrected WDI is 0.67. It corresponds to an error reduction of 77% by correcting the WDI for trees casting shadow effects.

In Fig. 8(a), the noncorrected WDI ranges from 0.2 to 1. In fact, the difference between the minimum T_s (299.7 K) and T_{air} at 10:30 A.M. (297.7 K, wet edge value) is 2 K, which implies strictly positive WDI values. The spatial distribution of WDI generally reflects the variability in land cover/use. On the one hand, the southern part of the study area is covered with vines and orchards, and shows a mean WDI of 0.84. This is consistent with both large bare soil areas of intercrop (the intercrop herbaceous species are senescent at this time) and the relatively large size (compared to the interrow spacing of vineyard for instance) of a Landsat-7/8 thermal pixels. On the other hand, the northern part of the study area is mainly covered by holm oak dominated forest with a mean WDI of 0.66. As holm oak is able to efficiently deal with low levels of soil water availability, a lower value of WDI lower than in vineyard/orchards would be expected [1]. Further north, the slope along the Herault river witnesses particularly low values of WDI.

Fig. 8(b) presents the self-calibrated corrected WDI. Vineyards and orchards are not particularly affected by the correction—the (mean $\text{WDI}_{c,\text{self}}$ is 0.87—due to the near-zero slope correction a_{self} (see next paragraph). In contrast, $\text{WDI}_{c,\text{self}}$ is particularly contrasted and enhanced in the forest area. The mean $\text{WDI}_{c,\text{self}}$ now reaches 0.74 (increase of 12%), and very




Fig. 8. Maps and density histograms per dominant land cover class of (a) and (c) noncorrected WDI, and (b) and (d) self-calibrated corrected $WDI_{c,self}$ for Landsat-7 data on the 22th July, 2016. (a) Map of WDI. (b) Map of $WDI_{c,self}$. (c) Density histogram of WDI. (d) Density histogram of $WDI_{c,self}$.

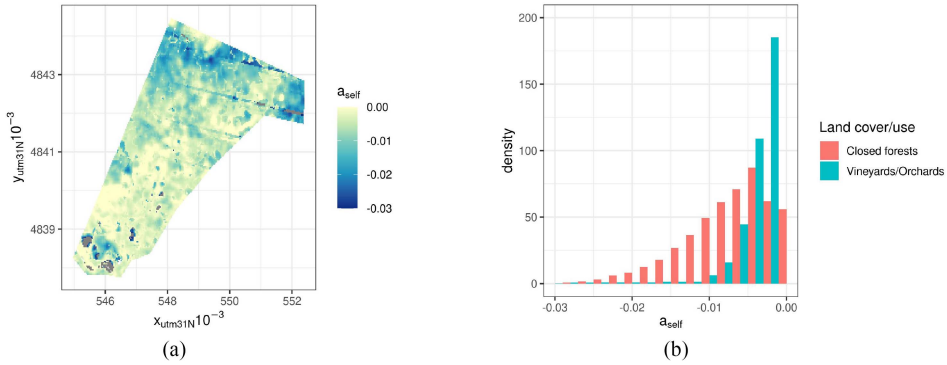


Fig. 9. (a) Map of the slope a_{self} of the self-calibrated correction equation over the study area and (b) density histograms of a_{self} per land use/cover classe.

few values are below 0.4. This is particularly true in the denser part of the forested area and along the Hérault river.

The correction slope a_{self} is mapped in Fig. 9(a) and density histograms of a_{self} values per dominant land use/cover class are provided in Fig. 9(b). Values of a_{self} are strongly related to the land cover map [see Fig. 2(a)] and to the elevation map [Fig. 2(b)]. In the southern part of the study area, vineyards and orchards (olive trees) show close to zero correction, with a mean slope correction of -0.003 [see Fig. 9(a) and (b)]. These land covers are characterized by large intercrops including bare soil areas or fast drying herbaceous species. Note that on the southern part, along the Hérault river, quarries provide high value of a_{self} . On the northern plateau where the flux tower is located, the *Quercus Illex* dominated forest is less open and witnesses more complex landscapes than orchards/vineyards, which implies a significant decrease in the mean a_{self} equal to -0.008 [see Fig. 9(a) and (b)]. The northern valley along the

Hérault river is characterized by very low a_{self} values, consistent with topographic effects. Note that Landsat-7 artefacts (strips) are clearly visible. This is due to the impact of a key date (in particularly dry conditions) of the Landsat-7 time series used in the calibration of a_{self} .

IV. CONCLUSION

Until now, no method has allowed to correct satellite-derived WDI for trees casting shadow effects over large areas. To fill the gap, this study is based on solar zenith angle (θ_S) to predict in time the effect of cast shadows on WDI.

The objectives are: 1) to quantitatively assess the impact of θ_S on WDI during dry periods (high values of hydric stress), 2) to build a self-calibration method that corrects WDI on a pixel basis from θ_S and satellite data solely for operational use, and 3) to evaluate calibration strategies against in situ 1-EF used

as ground truth. The classical WDI method (without correction from cast shadow effects) is used as benchmark to evaluate the improvement of the corrections. The approach is tested using in situ data collected between 2015 and 2021 at the Puechabon site located in a holm-oak forest in Southern-east of France.

As a first assessment of the effect of θ_S on WDI, the error in WDI at the Puechabon site [WDI - (1-EF)] is correlated to θ_S ($R^2 = 0.59$). By applying the site calibrated correction of WDI for cast shadow, the slope of the linear regression between remotely sensed WDI and in situ 1-EF is much closer to 1: it increases from 0.21 to 0.63. In addition, the RMSE decreases from 0.17 to 0.12 and the correlation coefficient (R) increases from 0.32 to 0.62 for noncorrected and corrected WDI, respectively.

As a further step, a self-calibrated correction method is developed at the pixel scale, without relying on in situ data, by correlating high WDI values to θ_S on particularly dry dates. This correction method still succeeds in improving WDI estimates: the R, the slope of the linear regression, and the RMSE are 0.57 (0.32), 0.50 (0.21), and 0.12 (0.17) for the corrected (noncorrected) WDI, respectively. Therefore, the self-calibrated method provides an operational workflow for practical use.

When comparing the correction results in dry and wet conditions, relatively low values of correlation (0.36 and 0.35) and slope of the linear regression (0.37 and 0.29) between satellite WDI and in situ 1-EF are obtained for the Wet dataset for self- and site-calibrated corrected WDI, respectively. In fact, the calibration strategy that relies on dry dates is not suitable for wet conditions, as the Ts contrast between sunny and shaded areas decreases in cool/wet conditions. It is also assumed that other physical factors than θ_S can affect the thermal behavior of forests, especially when the hydric stress is relatively low (e.g., thermal inertia [68], [69]).

Although quite promising results were obtained at the Puechabon site using our simple θ_S -based correction method, the approach should be tested to other sites including a variety of tree species and landscapes. In particular, we used the cumulative rain with a 15-day time depth to extract the Very Dry dataset for calibration purposes. The genericity of such an assumption should be assessed at other sites as this value might be linked to both soil water availability and tree physiological functioning. In addition, we set the intercept b_{self} to the minimum of θ_S , while Landsat viewing zenith is near nadir in the Puechabon site area. Note that it is not general as the Landsat-8 viewing angle can reach 8° , which suggests nonnegligible directional effects at the edges of the swath.

Several of the limitations mentioned above could be removed by implementing a physically based 3-D radiative transfer model like DART [70]. However, this would require the combined use of energy balance models to precisely solve the temperature of soil and vegetation components [71], [72]. Last but not least, this would also require a precise and exhaustive 3-D digital mock-up of the study area, which remains challenging due to both the lack of detailed knowledge of complex land surfaces and the constraints associated with calculation times. The TRISHNA mission, to be launched in 2025, will provide thermal data at high spatio-temporal resolution. The high temporal frequency

of TRISHNA data is related to the relatively large swath width of the instrument, which will imply significant viewing angle directional effects [73], [74]. Thus correcting for directional effects is especially relevant for the future operational use of these valuable data.

ACKNOWLEDGMENT


The authors would like to thank the principal investigator of the FLUXNET Puechabon site, Jean-Marc Limousin.

REFERENCES

- [1] J.-M. Limousin et al., "Drought acclimation of *Quercus ilex* leaves improves tolerance to moderate drought but not resistance to severe water stress," *Plant, Cell Environ.*, vol. 45, no. 7, pp. 1967–1984, 2022.
- [2] C. Ollivier et al., "An evapotranspiration model driven by remote sensing data for assessing groundwater resource in karst watershed," *Sci. Total Environ.*, vol. 781, 2021, Art. no. 146706.
- [3] R. Seidl, M. Schelhaas, W. Rammer, and P. Verkerk, "Increasing forest disturbances in Europe and their impact on carbon storage," *Nature Climate Change*, vol. 4, no. 9, pp. 806–810, 2014.
- [4] M. N. Gebeyehu and F. H. Hirpo, "Review on effect of climate change on forest ecosystem," *Int. J. Environ. Sci. Natural Resour.*, vol. 17, no. 4, pp. 126–129, Feb. 2019.
- [5] R. L. Peters, "Effects of global warming on forests," *Forest Ecol. Manage.*, vol. 35, no. 1, pp. 13–33, 1990.
- [6] IPCC, *Climate Change 2013—The Physical Science Basis: Working Group I. Contribution to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge, U.K.: Cambridge Univ. Press, 2014.
- [7] Y. Tramblay et al., "Challenges for drought assessment in the mediterranean region under future climate scenarios," *Earth-Sci. Rev.*, vol. 210, 2020, Art. no. 103348.
- [8] M. P. González-Dugo et al., "Long-term water stress and drought assessment of mediterranean oak savanna vegetation using thermal remote sensing," *Hydrol. Earth Syst. Sci.*, vol. 25, no. 2, pp. 755–768, 2021.
- [9] R. H. Nolan et al., "Linking forest flammability and plant vulnerability to drought," *Forests*, vol. 11, no. 7, 2020, Art. no. 779.
- [10] J. S. Littell, D. L. Peterson, K. L. Riley, Y. Liu, and C. H. Luce, "A review of the relationships between drought and forest fire in the United States," *Glob. Change Biol.*, vol. 22, no. 7, pp. 2353–2369, 2016.
- [11] G. Boulet et al., "The sparse model for the prediction of water stress and evapotranspiration components from thermal infra-red data and its evaluation over irrigated and rainfed wheat," *Hydrol. Earth Syst. Sci.*, vol. 19, no. 11, pp. 4653–4672, 2015.
- [12] Z. Su, "The surface energy balance system (SEBS) for estimation of turbulent heat fluxes," *Hydrol. Earth Syst. Sci.*, vol. 6, no. 1, pp. 85–100, 2002.
- [13] E. Delogu et al., "Evaluation of the sparse dual-source model for predicting water stress and evapotranspiration from thermal infrared data over multiple crops and climates," *Remote Sens.*, vol. 10, no. 11, 2018, Art. no. 1806.
- [14] J. Chirouze et al., "Intercomparison of four remote-sensing-based energy balance methods to retrieve surface evapotranspiration and water stress of irrigated fields in semi-arid climate," *Hydrol. Earth Syst. Sci.*, vol. 18, no. 3, pp. 1165–1188, 2014.
- [15] M. Moran, T. Clarke, Y. Inoue, and A. Vidal, "Estimating crop water deficit using the relation between surface-air temperature and spectral vegetation index," *Remote Sens. Environ.*, vol. 49, no. 3, pp. 246–263, 1994.
- [16] L. Jiang and S. Islam, "A methodology for estimation of surface evapotranspiration over large areas using remote sensing observations," *Geophysical Res. Lett.*, vol. 26, no. 17, pp. 2773–2776, 1999.
- [17] L. Jiang et al., "A satellite-based daily actual evapotranspiration estimation algorithm over south Florida," *Glob. Planet. Change*, vol. 67, no. 1, pp. 62–77, 2009.
- [18] G. Roerink, Z. Su, and M. Menenti, "S-SEBI: A simple remote sensing algorithm to estimate the surface energy balance," *Phys. Chem. Earth, Part B: Hydrol., Oceans Atmos.*, vol. 25, no. 2, pp. 147–157, 2000.
- [19] O. Merlin, "An original interpretation of the wet edge of the surface temperature–Albedo space to estimate crop evapotranspiration (SEB-1S), and its validation over an irrigated area in northwestern Mexico," *Hydrol. Earth Syst. Sci.*, vol. 17, no. 9, pp. 3623–3637, 2013.

- [20] R. Tang, Z.-L. Li, and B. Tang, "An application of the Ts-Vi triangle method with enhanced edges determination for evapotranspiration estimation from modis data in arid and semi-arid regions: Implementation and validation," *Remote Sens. Environ.*, vol. 114, no. 3, pp. 540–551, 2010.
- [21] K. Wang, Z. Li, and M. Cribb, "Estimation of evaporative fraction from a combination of day and night land surface temperatures and NDVI: A new method to determine the Priestley–Taylor parameter," *Remote Sens. Environ.*, vol. 102, no. 3, pp. 293–305, 2006.
- [22] E. Chuvieco et al., "Combining NDVI and surface temperature for the estimation of live fuel moisture content in forest fire danger rating," *Remote Sens. Environ.*, vol. 92, no. 3, pp. 322–331, 2004.
- [23] C. Collins, S. McElroy, M. Moran, R. Bryant, T. Miura, and W. Emerich, "Temporal and spatial changes in grassland transpiration detected using landsat TM and ETM+ imagery," *Can. J. Remote Sens.*, vol. 29, pp. 259–270, 2003.
- [24] E. S. Koksals, "Irrigation water management with water deficit index calculated based on oblique viewed surface temperature," *Irrigation Sci.*, vol. 27, pp. 41–56, 2008.
- [25] N. Virlet, V. Lebourgeois, S. Martinez, E. Costes, S. Labbé, and J.-L. Regnard, "Stress indicators based on airborne thermal imagery for field phenotyping a heterogeneous tree population for response to water constraints," *J. Exp. Botany*, vol. 65, no. 18, pp. 5429–5442, 2014.
- [26] A. Vidal and C. Devaux-Ros, "Evaluating forest fire hazard with a Landsat TM derived water stress index," *Agricultural Forest Meteorol.*, vol. 77, no. 3, pp. 207–224, 1995.
- [27] A. J. Prata, V. Caselles, C. Coll, J. A. Sobrino, and C. Ottlé, "Thermal remote sensing of land surface temperature from satellites: Current status and future prospects," *Remote Sens. Rev.*, vol. 12, no. 3/4, pp. 175–224, 1995.
- [28] P. C. Guillevic et al., "Directional viewing effects on satellite land surface temperature products over sparse vegetation canopies—A multisensor analysis," *IEEE Geosci. Remote Sens. Lett.*, vol. 10, no. 6, pp. 1464–1468, Nov. 2013.
- [29] P. Guillevic, J. P. Gastellu-Etchegorry, J. Demarty, and L. Prévot, "Thermal infrared radiative transfer within three-dimensional vegetation covers," *J. Geophysical Res.: Atmos.*, vol. 108, no. D8, 2003, pp. 4248–4261.
- [30] A. C. T. Pinheiro, J. L. Privette, and P. Guillevic, "Modeling the observed angular anisotropy of land surface temperature in a savanna," *IEEE Trans. Geosci. Remote Sens.*, vol. 44, no. 4, pp. 1036–1047, Apr. 2006.
- [31] D. Luquet, A. Vidal, J. Dauzat, A. Bégue, A. Olioso, and P. Clouvel, "Using directional TIR measurements and 3D simulations to assess the limitations and opportunities of water stress indices," *Remote Sens. Environ.*, vol. 90, no. 1, pp. 53–62, 2004.
- [32] G. Sepulcre-Cantó, P. Zarco-Tejada, J. Mnoz, J. Sobrino, E. de Miguel, and F. Villalobos, "Detection of water stress in an olive orchard with thermal remote sensing imagery," *Agricultural Forest Meteorol.*, vol. 136, no. 1, pp. 31–44, 2006.
- [33] L. Testi, D. Goldhamer, F. Iniesta, and M. Salinas, "Crop water stress index is a sensitive water stress indicator in pistachio trees," *Irrigation Sci.*, vol. 26, pp. 395–405, 2008.
- [34] N. Liu et al., "Thermal remote sensing of plant water stress in natural ecosystems," *Forest Ecol. Manage.*, vol. 476, 2020, Art. no. 118433.
- [35] I. García-Tejero et al., "Thermal imaging to monitor the crop-water status in almonds by using the non-water stress baselines," *Scientia Horticulturae*, vol. 238, pp. 91–97, 2018.
- [36] G. Egea, C. M. Padilla-Díaz, J. Martínez-Guanter, J. E. Fernández, and M. Pérez-Ruiz, "Assessing a crop water stress index derived from aerial thermal imaging and infrared thermometry in super-high density olive orchards," *Agricultural Water Manage.*, vol. 187, pp. 210–221, 2017.
- [37] A. Matese et al., "Estimation of water stress in grapevines using proximal and remote sensing methods," *Remote Sens.*, vol. 10, no. 1, 2018, Art. no. 114.
- [38] T. Poblete, S. Ortega-Farías, and D. Ryu, "Automatic coregistration algorithm to remove canopy shaded pixels in UAV-borne thermal images to improve the estimation of crop water stress index of a drip-irrigated Cabernet Sauvignon vineyard," *Sensors*, vol. 18, no. 2, 2018, Art. no. 397.
- [39] S. Lu, J. Xuan, T. Zhang, X. Bai, F. Tian, and S. Ortega-Farías, "Effect of the shadow pixels on evapotranspiration inversion of vineyard: A high-resolution UAV-based and ground-based remote sensing measurements," *Remote Sens.*, vol. 14, no. 9, 2022, Art. no. 2259.
- [40] B. Gardner, D. Nielsen, and C. Shock, "Infrared thermometry and the crop water stress index. II. sampling procedures and interpretation," *J. Prod. Agriculture*, vol. 5, pp. 466–475, 1992.
- [41] I. Leinonen and H. G. Jones, "Combining thermal and visible imagery for estimating canopy temperature and identifying plant stress," *J. Exp. Botany*, vol. 55, no. 401, pp. 1423–1431, 2004.
- [42] X. Wang, W. Yang, A. Wheaton, N. Cooley, and B. Moran, "Automated canopy temperature estimation via infrared thermography: A first step towards automated plant water stress monitoring," *Comput. Electron. Agriculture*, vol. 73, no. 1, pp. 74–83, 2010.
- [43] J. M. Limousin, S. Rambal, J. M. Ourcival, A. Rocheteau, R. Joffre, and R. Rodríguez-Cortina, "Long-term transpiration change with rainfall decline in a Mediterranean Quercus ilex forest," *Glob. Change Biol.*, vol. 15, no. 9, pp. 2163–2175, 2009.
- [44] S. Rambal et al., "Drought controls over conductance and assimilation of a mediterranean evergreen ecosystem: Scaling from leaf to canopy," *Glob. Change Biol.*, vol. 9, no. 12, pp. 1813–1824, 2003.
- [45] V. Allard, J. Ourcival, S. Rambal, R. Joffre, and A. Rocheteau, "Seasonal and annual variation of carbon exchange in an evergreen mediterranean forest in southern France," *Glob. Change Biol.*, vol. 14, no. 4, pp. 714–725, 2008.
- [46] T. Maruyama and M. Segawa, "Reciprocal analysis of sensible and latent heat fluxes in a forest region using single height temperature and humidity based on the bowen ratio concept," *J. Water Resour. Protection*, vol. 08, pp. 724–742, 2016.
- [47] C. Jiang and Y. Ryu, "Multi-scale evaluation of global gross primary productivity and evapotranspiration products derived from breathing Earth system simulator (BESS)," *Remote Sens. Environ.*, vol. 186, pp. 528–547, 2016.
- [48] G. Hu, L. Jia, and M. Menenti, "Comparison of MOD16 and LSA-SAF MSG evapotranspiration products over Europe for 2011," *Remote Sens. Environ.*, vol. 156, pp. 510–526, 2015.
- [49] Y. Ryu et al., "On the temporal upscaling of evapotranspiration from instantaneous remote sensing measurements to 8-day mean daily-sums," *Agricultural Forest Meteorol.*, vol. 152, pp. 212–222, 2012.
- [50] R. Crago and W. Brutsaert, "Daytime evaporation and the self-preservation of the evaporative fraction and the bowen ratio," *J. Hydrol.*, vol. 178, no. 1, pp. 241–255, 1996.
- [51] L. Jiang, S. Islam, and T. N. Carlson, "Uncertainties in latent heat flux measurement and estimation: Implications for using a simplified approach with remote sensing data," *Can. J. Remote Sens.*, vol. 30, no. 5, pp. 769–787, 2004.
- [52] G. Schmidt, C. Jenkerson, J. Masek, E. Vermote, and F. Gao, "Landsat ecosystem disturbance adaptive processing system (LEDAPS) algorithm description," U. S. Geological Surv., Reston, VA, USA, Open-File Rep. 2013-1057, 2013.
- [53] E. Vermote, C. Justice, M. Claverie, and B. Franch, "Preliminary analysis of the performance of the landsat 8/OLI land surface reflectance product," *Remote Sens. Environ.*, vol. 185, pp. 46–56, 2016.
- [54] S. Qiu, Z. Zhu, R. Shang, and C. J. Crawford, "Can landsat 7 preserve its science capability with a drifting orbit?," *Sci. Remote Sens.*, vol. 4, 2021, Art. no. 100026.
- [55] T. Carlson and D. Ripley, "On the relation between NDVI, fractional vegetation cover, and leaf area index," *Remote Sens. Environ.*, vol. 62, no. 3, pp. 241–252, 1997.
- [56] M. J. Cook, *Atmospheric Compensation for a Landsat Land Surface Temperature Product*. Rochester, NY, USA: Rochester Inst. Technol., 2014.
- [57] M. Cook, J. R. Schott, J. Mandel, and N. Raqueno, "Development of an operational calibration methodology for the landsat thermal data archive and initial testing of the atmospheric compensation component of a land surface temperature (LST) product from the archive," *Remote Sens.*, vol. 6, no. 11, pp. 11244–11266, 2014.
- [58] G. Boulet, A. Chehbouni, P. Gentine, B. Duchemin, J. Ezzahar, and R. Hadria, "Monitoring water stress using time series of observed to unstressed surface temperature difference," *Agricultural Forest Meteorol.*, vol. 146, no. 3, pp. 159–172, 2007.
- [59] A. Karnieli et al., "Use of NDVI and land surface temperature for drought assessment: Merits and limitations," *J. Climate*, vol. 23, no. 3, pp. 618–633, 2010.
- [60] P. D. Colaizzi et al., "Two-source energy balance model estimates of evapotranspiration using component and composite surface temperatures," *Adv. Water Resour.*, vol. 50, pp. 134–151, 2008.
- [61] D. Zhang et al., "Surface soil water content estimation from thermal remote sensing based on the temporal variation of land surface temperature," *Remote Sens.*, vol. 6, no. 4, pp. 3170–3187, 2014.

- [62] A. Amazirh et al., "Retrieving surface soil moisture at high spatio-temporal resolution from a synergy between sentinel-1 radar and landsat thermal data: A study case over bare soil," *Remote Sens. Environ.*, vol. 211, pp. 321–337, 2018.
- [63] L. Jiang and S. Islam, "Estimation of surface evaporation map over southern great plains using remote sensing data," *Water Resour. Res.*, vol. 37, no. 2, pp. 329–340, 2001.
- [64] R. Tang, Z.-L. Li, M. Liu, Y. Jiang, and Z. Peng, "A moisture-based triangle approach for estimating surface evaporative fraction with time-series of remotely sensed data," *Remote Sens. Environ.*, vol. 280, 2022, Art. no. 113212.
- [65] A. de Tomás, H. Nieto, R. Guzinski, J. Salas, I. Sandholt, and P. Berliner, "Validation and scale dependencies of the triangle method for the evaporative fraction estimation over heterogeneous areas," *Remote Sens. Environ.*, vol. 152, pp. 493–511, 2014.
- [66] K. Nishida, R. R. Nemani, S. W. Running, and J. M. Glassy, "An operational remote sensing algorithm of land surface evaporation," *J. Geophysical Res.: Atmos.*, vol. 108, no. D9, 2003, Art. no. 4270.
- [67] M. C. Anderson et al., "Mapping daily evapotranspiration at field to continental scales using geostationary and polar orbiting satellite imagery," *Hydrol. Earth Syst. Sci.*, vol. 15, no. 1, pp. 223–239, 2011.
- [68] N. Gaudio, X. Gendre, M. Saudreau, V. Seigner, and P. Balandier, "Impact of tree canopy on thermal and radiative microclimates in a mixed temperate forest: A new statistical method to analyse hourly temporal dynamics," *Agricultural Forest Meteorol.*, vol. 237–238, pp. 71–79, 2017.
- [69] V. Haverd, M. Cuntz, R. Leuning, and H. Keith, "Air and biomass heat storage fluxes in a forest canopy: Calculation within a soil vegetation atmosphere transfer model," *Agricultural Forest Meteorol.*, vol. 147, no. 3, pp. 125–139, 2007.
- [70] J.-P. Gastellu-Etchegorry et al., "Discrete anisotropic radiative transfer (dart 5) for modeling airborne and satellite spectroradiometer and lidar acquisitions of natural and urban landscapes," *Remote Sens.*, vol. 7, no. 2, pp. 1667–1701, 2015.
- [71] Y. Malbêteau et al., "Normalizing land surface temperature data for elevation and illumination effects in mountainous areas: A case study using aster data over a steep-sided valley in Morocco," *Remote Sens. Environ.*, vol. 189, pp. 25–39, 2017.
- [72] S. Mwangi, G. Boulet, and A. Olioso, "Assessment of an extended sparse model for estimating evapotranspiration from directional thermal infrared data," *Agricultural Forest Meteorol.*, vol. 317, 2022, Art. no. 108882.
- [73] L. Buffet, P. Gamet, P. Maisongrande, C. Salcedo, and P. Crebassol, "The TIR instrument on TRISHNA satellite: A precursor of high resolution observation missions in the thermal infrared domain," *Proc. SPIE*, vol. 11852, 2021, Art. no. 118520Q.
- [74] J.-P. Lagouarde et al., "The Indian–French Trishna mission: Earth observation in the thermal infrared with high spatio-temporal resolution," in *Proc. IEEE Int. Geosci. Remote Sens. Symp., Inst. Elect. Electron. Engineers*, 2018, pp. 4078–4081.



Victor Penot received the engineering degree in meteorology and water management from the Ecole des Ponts - Paristech, Champs-sur-Marne, France, in 2013, and the master's degree in public planning from the Université Grenoble Alpes, Grenoble, France, in 2014. He is currently working toward the Ph.D. degree in predicting the risk and severity of forest fires using remote sensing data with CESBIO, Toulouse, France, since 2021.

He was an Associate Professor of Mathematics, in high school H.Parriat, Montceau-les-Mines, France, in 2015, and joined the University of Toulouse 3, Toulouse, France, in 2019, to teach spatial and biological data analysis. His research interests include the fields of natural hazard management, particularly in forested areas and woodland urban interfaces, and focus on the use of optical/thermal remote sensing data and meteorological data related to fuel hydric and phenological behavior before a forest fire, in Mediterranean ecosystems.



Olivier Merlin received the engineering degree in nuclear physics from the Ecole Nationale Supérieure de Physique de Grenoble, Grenoble, France, in 2000, the M.S. degree in techniques for space from the Ecole Nationale Supérieure de l'Aéronautique et de l'Espace, Toulouse, France, in 2001, and the Ph.D. degree in remote sensing and hydrology from the Université Paul Sabatier, Toulouse, France, in 2005.

He is notably recognized for his work in developing original methods that improve the spatial resolution of satellite data and spatialize hydrological processes more realistically. In addition to methodological developments, he has applied his skills to themes of high societal interest associated with agricultural production and risk prevention. In 2008, he joined CNRS as a Researcher with CESBIO, Toulouse, France. He has supervised 15 Ph.D., coordinated several French ANR and European projects, and animated cross-disciplinary themes. He was seconded with IRD, Marseille, France, to the University of Cadi Ayyad, Marrakesh, Morocco, from 2013 to 2017. He has been involved in the exploitation of SMOS data, from 2010, and is currently contributing to the preparation of the TRISHNA mission. His research interests include the use of multisensor remote sensing to monitor changes in water resources.

Chapitre 7

Conclusion et perspectives

7.1 Contexte des travaux de thèse

Cette thèse porte sur la prédiction de la sévérité potentielle des incendies de forêt ainsi que sur l'estimation du stress hydrique des forêts par télédétection optique/thermique haute résolution en zone méditerranéenne. La prédiction de la sévérité potentielle permet d'évaluer l'influence des pratiques de gestion et/ou des politiques publiques de réduction des impacts des incendies sans attendre qu'ils se déclarent. Il s'agit de la première étude de la sévérité des incendies en zone méditerranéenne française. A ce jour, la prédiction de la sévérité potentielle dans les autres parties du globe reste un défi. De plus, afin d'améliorer l'estimation du stress hydrique du combustible vivant, jusque là estimé à partir de modèles météorologiques uniquement, l'utilisation de la télédétection optique/thermique haute résolution est envisagée. Cependant, les méthodes de référence utilisant les données optiques/thermiques pour estimer le stress hydrique doivent être testées sur les forêts méditerranéennes.

Les travaux se sont concentrés sur l'arc méditerranéen français, une des aires historiques des feux de forêt, qui présente une large hétérogénéité de milieux et de conditions de surface, avec un fractionnement important du paysage. Les données satellitaires utilisées (Sentinel-2, Landsat-7/8/9) permettent des acquisitions répondant aux contraintes de morcellement de l'espace grâce à leur haute résolution spatiale (10-100 m), tout en ayant une période de revisite compatible avec l'évolution temporelle de l'état du combustible (hebdomadaire). Les enjeux de l'utilisation de ces données reposent sur l'extraction de proxys d'état du combustible (eg ratio mort/vivant, contenu en eau du combustible vivant (*LFMC*)). Tout d'abord les séries temporelles pré-feu de proxys de l'état du combustible issus des données satellitaires optiques et du système météorologique Indice Feu Météo ont été utilisées pour prédire la sévérité potentielle des feux de forêts. Ensuite, une approche de référence a utilisé les données satellitaires optiques/thermiques à haute résolution spatiale pour estimer le stress hydrique sur forêt et des corrections ont été proposées.

7.2 Synthèse de l'étude

Une première partie s'est intéressée à la prédiction statistique de la sévérité potentielle estimée par deux indices de sévérité issus de la télédétection optique (*FSI*) – *RBR* et *NBR_{post}* – à partir des séries temporelles pré-feu d'indices issus de la télédétection satellitaire (*NDVI*) et météorologiques (*DMC*, *DC*) évaluées sur 179 intersections spatiales Feu-OS (79 incendies estivaux entre 2016 et 2021). A titre de comparaison, le modèle de référence dans l'état de l'art n'utilise que les données mesurées ou évaluées juste avant l'incendie. Quel que soit le *FSI*, la connaissance des dynamiques estimées du combustible entre 2

et 2.2 mois avant l'incendie est suffisante pour obtenir une amélioration de la prédiction de la sévérité par rapport au modèle de référence. Les performances de prédiction (corrélation entre les valeurs prédites du FSI et les valeurs dérivées des mesures satellitaires, R) du modèle utilisant les séries temporelles sont $R = 0.68$ et $R = 0.46$ pour le RBR et le NBR_{post} respectivement contre $R = 0.52$ et $R = 0.34$ pour le RBR et le NBR_{post} respectivement (modèle de référence). Une augmentation plus rapide que la moyenne de la sécheresse atmosphérique (ie faible humidité relative et haute température de l'air) et l'absence de précipitations (quantifiées par le DMC) au cours des 2-2.2 mois avant l'incendie favorisent des sévérités plus élevées que la moyenne. Une diminution rapide de la quantité de combustible vivant (augmentation du combustible mort), caractérisée par une diminution plus rapide que la moyenne du $NDVI$, et un faible $NDVI$ le jour de l'incendie, contribuent aussi à atteindre des sévérités plus élevées que la moyenne. Bien que ces résultats montrent un apport significatif des séries temporelles, les performances de prédiction diffèrent entre le RBR , un indice bi-temporel, et le NBR_{post} qui ne prend en compte que les conditions post-feu. Cette différence de performances de prédiction doit être analysée.

Dans l'objectif d'établir une prédiction robuste de la sévérité potentielle, il est possible de prédire quatre FSI (bi-temporels pré/post-feu : $dNBR$, RBR , $RdNBR$; mono-temporel post-feu : NBR_{post}) dont la corrélation avec la sévérité de terrain est scientifiquement établie. Une fois prédits, des seuils déjà établis au sein d'études de référence permettent de classer chaque FSI en niveau de sévérité terrain (modélisation d'ensemble). Avant d'effectuer les prédictions des quatre FSI , il est important de vérifier qu'ils atteignent des performances de prédiction similaires, et sinon, d'en analyser les différences. L'approche de référence présentée au paragraphe précédent a été utilisée pour effectuer cette comparaison. Les résultats montrent que les quatre FSI n'atteignent pas la même performance de prédiction (R varie entre 0.35 et 0.74). Les performances de prédictions des FSI bi-temporels varient linéairement et de manière croissante avec la dépendance du FSI aux conditions pré-feu (connues a priori et bien prédites sinon). Ainsi la comparaison des performances de prédictions entre FSI peut être trompeuse. Il est donc recommandé de concentrer les recherches sur la prédiction des conditions post-feu uniquement (NBR_{post}) qui ne dépendent pas des conditions pré-feu. Cependant, le NBR_{post} reste insuffisamment prédit. Une des pistes d'amélioration envisagée est l'intégration de proxys de stress hydrique issus de la télédétection optique/thermique.

L'utilisation d'estimations de la fraction évaporative (EF) – proxy de stress hydrique – dérivées des données optiques/thermiques Landsat dans les modèles de sévérité, requiert d'évaluer la bonne qualité des estimations de EF sur forêt. Ces estimations de EF ont été dérivées d'une méthode de référence en milieu de faible hauteur de couvert (méthode contextuelle $LST - f_{vg}$). L'évaluation a été mise en œuvre sur deux sites forestiers méditerranéens (Puechabon et Fontblanche) durant 9 années entre les mois d'avril et d'octobre. Ces deux sites diffèrent par leurs espèces dominantes (Chêne vert et Pin d'Alep pour Puechabon et Fontblanche respectivement) et leurs hauteurs dominantes (5.5 et 13 m respectivement). Conformément aux résultats issus de la bibliographie, EF est largement surestimée sur les deux sites (biais=0.24), ce qui entraîne une sous-estimation du flux de chaleur sensible H (biais=-162 $W.m^{-2}$, $R = 0.39$) et une surestimation du flux de chaleur latente LE (biais=132 $W.m^{-2}$, $R = 0.06$), en particulier dans des conditions sèches (H très supérieur à LE). Les tendances des erreurs d'estimation de EF commises sur les deux sites sont différentes, avec un biais positif particulièrement important à Fontblanche (biais=0.36 contre biais=0.11 à Puechabon) où la hauteur dominante est la plus importante.

L'hypothèse expliquant l'erreur d'estimation de EF au premier ordre est la rugosité du couvert végétal dont un proxy est la hauteur de la canopée (hc). Au sein de la zone d'étude, les différences de rugosité (hc) pour une même fraction de végétation verte (f_{vg}) ne peuvent pas être prises en compte par la méthode $LST - f_{vg}$. Pourtant, l'hétérogénéité de rugosité (hc) peut induire pour un même stress hydrique et un même f_{vg} des LST différentes. Pour étudier cet effet, les LST Landsat des zones d'étude ont été mises en regard des hc dérivées des mesures LiDAR haute définition de l'IGN. Tout d'abord il est montré qu'à

partir d'une hc d'environ 40 m, commune aux deux aires d'études, la LST n'est plus couplée aux flux turbulents. A partir de cette grandeur, une méthode de normalisation des effets de hc a été développée. Cette normalisation produit LST_{norm} équivalente à LST pour $hc = 0$. Par la suite, LST_{norm} a été utilisée dans l'approche contextuelle $LST_{norm} - f_{vg}(Tsd_{context})$ (bord sec plat estimé contextuellement) pour estimer H , LE et EF . Les corrélations sur H ($R = 0.72$) et LE ($R = 0.36$) sont améliorées par rapport à l'approche $LST - f_{vg}$. Les erreurs d'estimation de EF pour les deux sites ont les mêmes tendance (biais=0.25 et biais=0.22 pour Puechabon et Fontblanche respectivement). Ainsi, la normalisation des effets de hc a pour conséquence de permettre aux erreurs d'estimation de EF des deux sites d'être analysées et corrigées de manière commune, indépendamment des caractéristiques de structure des deux sites. Une troisième approche ($LST_{norm} - f_{vg}(Tsd_{EB})$, bord sec plat simulé par un modèle bilan d'énergie identiquement paramétré pour les deux sites) permet de réintroduire les dynamiques temporelles du forçage météorologique sur H , LE et EF ($R = 0.71 / 0.41 / 0.45$ et biais=-30 W.m⁻² / -1 W.m⁻² / 0.01 pour $H / LE / EF$). A ce jour, c'est la première fois que cette qualité d'estimation est atteinte sur ces sites en même temps et que l'utilisation de données LiDAR associées à une approche contextuelle est mise en place. Cependant, l'utilisation du modèle bilan d'énergie, en simulant une température de sol nu sec qui sous-estime la température de sol nu sec observée, permet de solutionner une sous-estimation de la LST sur forêt qui n'est pas prise en compte par la normalisation des effets de hc .

Un effet au second ordre expliquant les erreurs d'estimation de H , LE et EF sur les deux sites Eddy Covariance de Puechabon et Fontblanche, correspond aux effets directionnels à l'intérieur du pixel satellitaire (effet des ombres portées). Suite à l'estimation de EF par l'approche $LST_{norm} - f_{vg}(Tsd_{EB})$, l'erreur d'estimation de EF a été mise en regard d'un proxy supposé des effets d'ombres : l'angle zénithal solaire (θ_S). Les résultats montrent que θ_S est un bon proxy de l'effet des ombres portées (Corrélation de l'erreur sur EF vs θ_S de 0.44 et 0.37 pour Puechabon et Fontblanche respectivement) et que l'effet des ombres portées est négligeable pour θ_S proche du nadir. Ces résultats sont cohérents avec le fait que l'effet des ombres portées augmente avec la fraction d'ombre visible par le satellite. De plus, cet effet est important en conditions sèches. Cela valide l'hypothèse selon laquelle l'effet des ombres portées est d'autant plus important que la différence entre la LST de la canopée au soleil et la LST des parties ombragées (proche de T_{air}) est importante. Ces conditions se rencontrent dans des conditions de stress hydrique élevé. Enfin, une méthode opérationnelle a été développée pour corriger EF de l'effet des ombres portées. Les estimations de EF , H et LE issues de l'approche combinée $LST_{norm} - f_{vg}(Tsd_{EB})$ -Correction de l'effet des ombres portées sont de bonne qualité sur les deux sites en même temps ($R = 0.65 / 0.63$ (H), $R = 0.58 / 0.44$ (LE) et $R = 0.58 / 0.47$ (EF) pour Puechabon et Fontblanche respectivement). Cette approche combinée permet de normaliser des effets de hc tout en intégrant une correction des effets directionnels sur des structures tridimensionnelles complexes, comme les forêts.

7.3 Limitations et perspectives

L'étude sur la prédiction de la sévérité potentielle a montré la difficulté de prédire les conséquences d'un événement extrêmement brutal, un incendie, qui impose une discontinuité dans les états de surface. L'étude actuelle a été menée à l'échelle spatiale de l'intersection feu-occupation du sol. Pour aller plus loin, une suite possible à ces recherches serait de tester les approches à une échelle spatiale plus fine et plus cohérente avec la mise en place de politiques de diminution des impacts ($\approx 10-100$ m). Pour cela, plusieurs pistes sont à explorer :

- extension spatio-temporelle des sites et régions d'étude ;
- utilisation de modèles plus complexes ;

- estimation du ratio mort/vivant du combustible ;
- estimation des caractéristiques structurales du combustible ;
- amélioration de l'estimation du *LFMC* et suivi de l'état hydrique du combustible vivant.

7.3.1 Extension spatio-temporelle des sites et régions d'étude

Notre étude s'est portée sur le contexte Méditerranéen français durant au plus 10 ans. Les approches statistiques sont dépendantes du jeu de données d'entraînement et de test. En ce qui concerne la sévérité, il serait pertinent de tester les modèles développés sur des aires connexes (Espagne, Italie, Portugal, Grèce) pour tester leur robustesse, mais aussi d'évaluer les approches temporelles dans des conditions pédo-climatiques différentes, en dehors de l'aire Méditerranéenne. Des zones dans lesquelles les incendies se propagent plus librement (Australie, Mexique) apporteraient une plus-value intéressante. Des gradients de sévérité plus importants au sein des mêmes incendies y sont observés.

L'étude de l'estimation du stress hydrique n'a porté que sur deux sites d'étude. D'autres sites Eddy Covariance présentant des contextes similaires devraient être étudiés. Par exemple, certains sites européens (Italie, Espagne), aux USA ou en Australie présentent des similitudes avec les deux sites étudiés (milieux soumis à sécheresse et forestiers). A fortiori, sur ces sites, les approches classiques (modèle bilan d'énergie (Trebs et al., 2021)) faillissent.

7.3.2 Modèles de prédiction de la sévérité

L'approche FLM intègre les séries temporelles mais reste un modèle linéaire additif. Une approche mixte, combinant analyse de données fonctionnelles (eg pour estimer les scores sur des composantes principales) et apprentissage machine (Pesaresi et al., 2022) permettrait d'atteindre de meilleures performances de prédiction, au prix d'une plus faible explicabilité. Cette approche pourrait être mise en place une fois que des proxys de l'état du combustible atteindront de bonnes qualités d'estimation quelle que soit l'occupation du sol.

7.3.3 Estimation spatialisée du ratio mort/vivant

L'utilisation des séries temporelles pré-feu du *NDVI* a mis en évidence l'importance du ratio combustible mort/vivant. Ce ratio n'a pas été estimé ici mais peut-être un objectif à part entière dans le futur. Il a une influence importante sur la vitesse de propagation des incendies (Cruz et al., 2015; Duff et al., 2019) qui est directement liée à l'intensité du front de flamme. A ce jour il n'existe pas de proxy de ce ratio en opérationnel et issu de la télédétection. Les recherches à ce sujet sont assez peu nombreuses (Chaivanont et al., 2018; Chuvieco et al., 2002; Newnham et al., 2011; Ruthrof et al., 2016). L'utilisation de données optiques et/ou de données radar (eg Sentinel-1), comparées à des mesures de terrain ou l'utilisation de modèles de transfert radiatif (sans radar dans ce cas), pourrait permettre d'estimer ce ratio. Le produit final serait d'une grande utilité pour mieux contraindre les modèles statistiques et/ou d'apprentissage machine, mais pourrait aussi être utilisé dans des modèles physiques (Costes, 2021) ou semi-empiriques (Cruz et al., 2015) de propagation des incendies.

7.3.4 Estimation des caractéristiques structurales du combustible

La structure du combustible n'est pas explicitement intégrée dans les modèles de prédiction de la sévérité développés dans cette étude (ou de manière indirecte via les classes d'occupation du sol). Pourtant, la structure du combustible a une influence avérée sur la sévérité (Gale and Cary, 2022; Gale et al., 2023).

Les données LiDAR à haute définition spatiale permettent de quantifier les structures horizontales et verticales du combustible et sont disponibles en France après 2023 (Martin-Ducup et al., 2025). Leur intégration dans les modèles de sévérité est une piste d'amélioration prometteuse.

7.3.5 Estimation du *LFMC* et suivi de l'état hydrique du combustible vivant

L'estimation du *LFMC* pour une utilisation dans les modèles de sévérité, et plus largement, pour assurer le suivi de l'état hydrique (stress hydrique et évapotranspiration) des forêts est aussi un enjeu majeur. A ce jour la plupart des modèles d'estimation du *LFMC* sont basés sur des indices météorologiques – non sensibles aux états de surface et disponibles à faible résolution spatiale – ou de données optiques (estimation indirecte du *LFMC*).

Les approches utilisant les données optiques/thermiques issues des missions satellitaires présentes et à venir offrent de belles perspectives. Elles permettent d'estimer directement le EF sur des bases physiques. Aussi, identifier les axes de recherches futures à ce sujet est primordial. L'utilisation de données thermiques issues de la télédétection suggère d'identifier l'ordre des différentes sources d'erreurs d'estimation de *EF* dérivée des méthodes contextuelles ou des modèles bilan d'énergie, soit : les effets de la topographie et les effets aérodynamiques de la rugosité puis les effets directionnels.

Un des effets au premier ordre sur les erreurs d'estimation de *EF* est l'effet de la topographie sur la *LST*. Tout d'abord, l'exposition (orientation et pente) influence directement le *R_g* reçu en surface, et ainsi la quantité d'énergie totale disponible en surface. Ensuite le gradient adiabatique (*T_{air}*) implique une diminution de la *LST* avec l'altitude pour de mêmes conditions de stress hydrique. Si ces deux facteurs ne sont pas normalisés au sein d'une zone d'étude, cela peut entraîner une sur/sous-estimation de *EF*. La normalisation des effets de la topographie est un sujet de recherche en cours (Malbêteau et al., 2017; Sebbar et al., 2023, 2024). Dans notre étude, les effets de la topographie ont été négligés en choisissant des aires d'études minimisant les gradients d'altitude. Pourtant, des effets d'exposition sont certainement présents. A titre d'illustration, la figure 7.1 présente l'altitude (a), la pente a_{auto} de la Correction Auto-calibrée de *EF* dérivée de la méthode $LST - f_{vg}$ pour l'aire d'étude de Puechabon, utilisant soit la *LST* dérivée des mesures satellitaires (b) soit la *LST* normalisée des effets topographiques selon la méthode de Malbêteau et al. (2017)¹(c). Si la *LST* n'est pas normalisée des effets topographiques, les effets des ombres portées sont négligeables (a_{auto} proche de 0) sur les expositions en pente au Sud (partie centrale de la zone d'étude ou au Nord, au nord de la vallée de l'Hérault). Ils sont plus importants (grandes valeurs absolues de a_{auto}) sur les expositions orientées au Nord en pente (Nord de la zone d'étude, au sud de la vallée de l'Hérault). Après normalisation des effets topographiques, les valeurs de a_{auto} entre les deux expositions convergent (voir figure 7.1 (c)). La différence résiduelle est due aux effets des ombres portées, conséquence d'une différence de couvert entre face Nord et face Sud ou à une rupture brutale dans topographie.

Les effets aérodynamiques de la rugosité (*hc*) sont un deuxième effet au premier ordre. L'extension des méthodes de normalisation/correction de ces effets à d'autres sites, requiert que l'ensemble des données nécessaires soient disponibles. Une couverture mondiale de *hc* à la résolution Landsat est disponible pour les zones forestières à partir des mesures Global Ecosystem Dynamics Investigation pour l'année 2019². Des approches d'apprentissage utilisant des données satellitaires optiques/radar permettent d'étendre et d'actualiser les cartes de *hc* (Potapov et al., 2021; Schwartz et al., 2024). Une mise à jour de *hc* au moins annuelle semble suffisante pour normaliser des effets de *hc* sur les forêts. Par ailleurs, une faiblesse des méthodes de normalisation proposées réside dans l'approche empirique de détermination des paramètres

1. <https://gitlab.com/victor.penot/thermalstressindex2cor>

2. <https://glad.umd.edu/dataset/gedi>

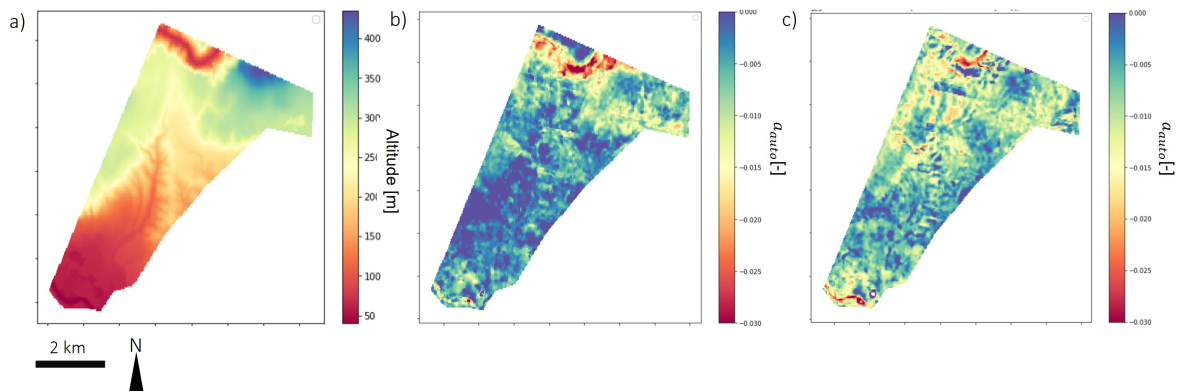


FIGURE 7.1 – Zone d'étude de Puechabon : altitude (a), pente a_{auto} de la Correction Auto-calibrée de EF dérivée de la méthode $LST - f_{vg}$ utilisant la LST dérivée des mesures satellitaires (b) et pente a_{auto} de la Correction Auto-calibrée de EF dérivée de la méthode $LST - f_{vg}$ utilisant la LST normalisée des effets topographiques (c)

de normalisation. L'utilisation du LiDAR à haute définition pourrait apporter des éléments permettant de renforcer la justification et la robustesse des normalisations. La figure 7.2 montre la carte à haute résolution spatiale de hc (résolution de 3 m) dérivée des données LiDAR de l'IGN autour des sites Eddy Covariance de Puechabon et Fontblanche. La carte des pentes dérivées de hc est également fournie. La zone forestière près du site Eddy Covariance de Puechabon montre une plus grande homogénéité de hc (pentes plus faibles) que la forêt près du site Eddy Covariance de Fontblanche. A proximité du site Eddy Covariance de Fontblanche, l'espace inter-houppier des pins fournit une grande colonne d'air qui favorise un couplage aérodynamique sol-canopée-atmosphère élevé (Rotenberg and Yakir, 2010, 2011), ce qui n'est pas le cas à Puechabon. Le site de Fontblanche, en raison de sa structure de canopée (arbres hauts, faible densité des tiges de la strate dominante) pourrait permettre une diminution de la LST plus importante que dans la zone d'étude de Puechabon (arbres bas, haute densité de tiges de la strate dominante). Ces données, éventuellement associées à des données thermiques à très haute résolution spatiale, peuvent permettre de mieux comprendre les effets structuraux de la canopée sur la LST (Bian et al., 2021; Richter et al., 2021; Still et al., 2021; Webster et al., 2018) et notamment de mieux modéliser et paramétrer la rugosité de surface dans les modèles bilan d'énergie.

Dans le cadre de la prise en compte des effets aérodynamiques de la rugosité, cette étude a aussi montré la complémentarité des modèles bilan d'énergie et des approches contextuelles. Les modèles bilan d'énergie peuvent être utilisés pour contraindre les conditions aux limites des méthodes contextuelles. Ils réintroduisent les dynamiques temporelles du forçage météorologique. Ils limitent aussi la dépendance aux conditions de surface observées dans la zone d'étude. Il n'existe qu'assez peu d'études portant sur la combinaison des deux approches (Long and Singh, 2012; Long et al., 2012; Moran et al., 1994; Stefan et al., 2015; Sun et al., 2017). L'un des désavantages opérationnels à utiliser un modèle bilan d'énergie est la nécessité d'avoir des données météorologiques en temps quasi réel. Par ailleurs, la paramétrisation du modèle bilan d'énergie peut s'avérer difficile. Cette étude a montré que l'utilisation des modèles bilan d'énergie peut se limiter à la simulation d'une température de sol sec (utilisation de LST normalisée des effets de hc), ce qui réduit la dépendance à l'estimation de paramètres complexes (eg rugosité sur la végétation). Cependant la rugosité n'est pas l'unique grandeur différenciant le sol nu de la végétation. Les caractéristiques radiatives (émissivité, albédo) ou encore le paramètre G/Rn différent (Kustas and Daughtry, 1990). Une meilleure compréhension et interprétation du sens physique de la LST normalisée des effets de hc pourrait permettre de mieux contraindre la paramétrisation des modèles bilan d'énergie.

Les effets directionnels (ombres portées) sont un effet du second ordre. Afin de mieux comprendre et




FIGURE 7.2 – Cartes de hc (a,c, à gauche) et pentes dérivées de hc (b,d, à droite) pour Puechabon (haut) et Fontblanche (bas) respectivement. Les cartes ont une résolution de 3 m et sont centrées sur la zone forestière a proximité des sites Eddy Covariance.

contraindre les paramètres de correction opérationnelle de l'effet des ombres portées, les données LiDAR peuvent aussi être exploitées. Elles peuvent être incorporées dans des approches contextuelles pour inférer l'effet des ombres portées et calibrer une correction. Par exemple, la LST au sein d'une zone d'étude peut être mise en regard de la variabilité sub-pixellaire de hc (écart-type) ou de la proportion d'ombres dans le pixel satellitaire (estimation déterministe de la fraction des zones ombragées vue par le satellite). Enfin, dans un avenir proche, la mission spatiale TRISHNA aura des angles zénithaux de vues plus importants (jusqu'à 34°) que les missions Landsat-7/8/9 utilisées ici (inférieurs à 2° pour Puechabon et 7° pour Fontblanche). Ce nouveau degré de liberté, négligé ici, sera à prendre en compte dans l'étude des effets directionnels.

Annexe A




FIGURE A.1 – Nuage de points du $LFMC$ déduit des mesures sur le Réseau Hydrique entre 2015 et 2021 en fonction de EF estimée par la méthode $LST - f_{vg}$ (a) et corrigée de l'effet des ombres portées (b)

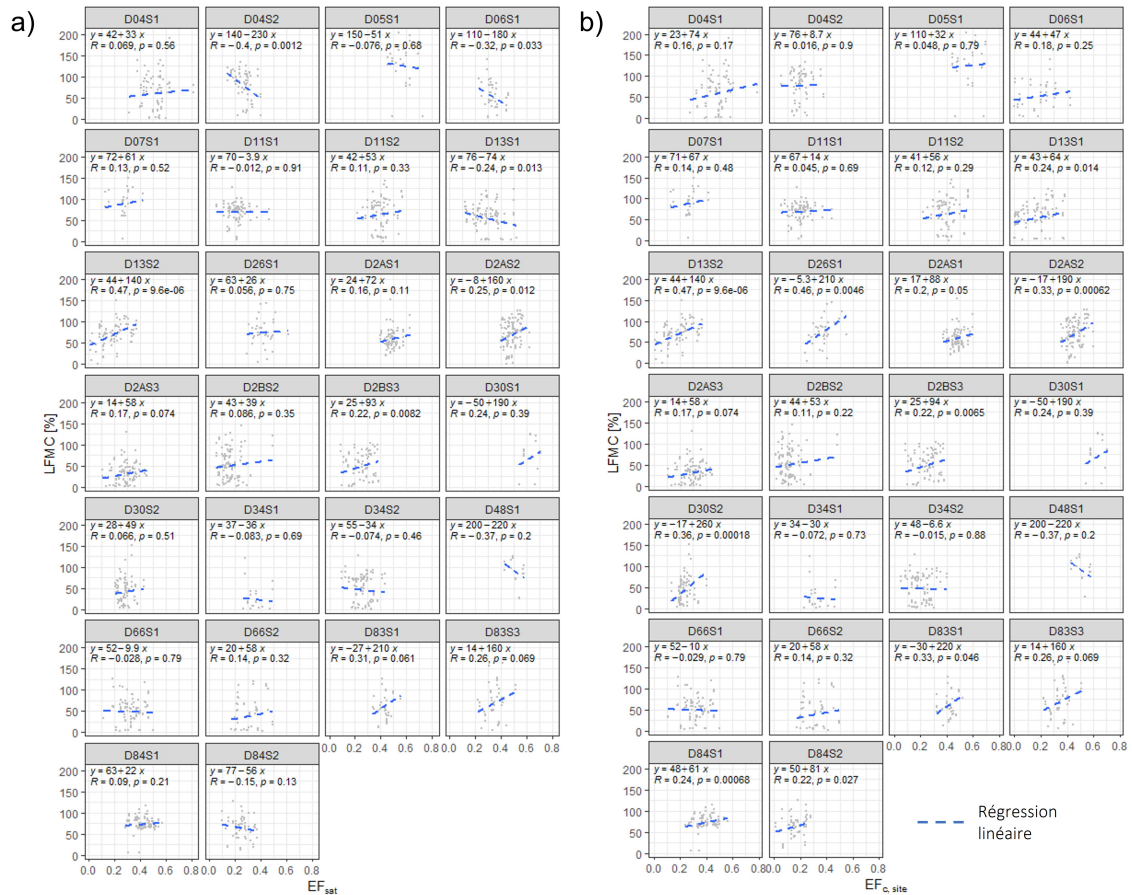


FIGURE A.2 – Nuage de points du $LFMC$ déduit des mesures sur le Réseau Hydrique entre 2015 et 2021 en fonction de EF estimée par la méthode $LST - f_{vg}$ (a) et corrigée de l'effet des ombres portées (b) par espèce

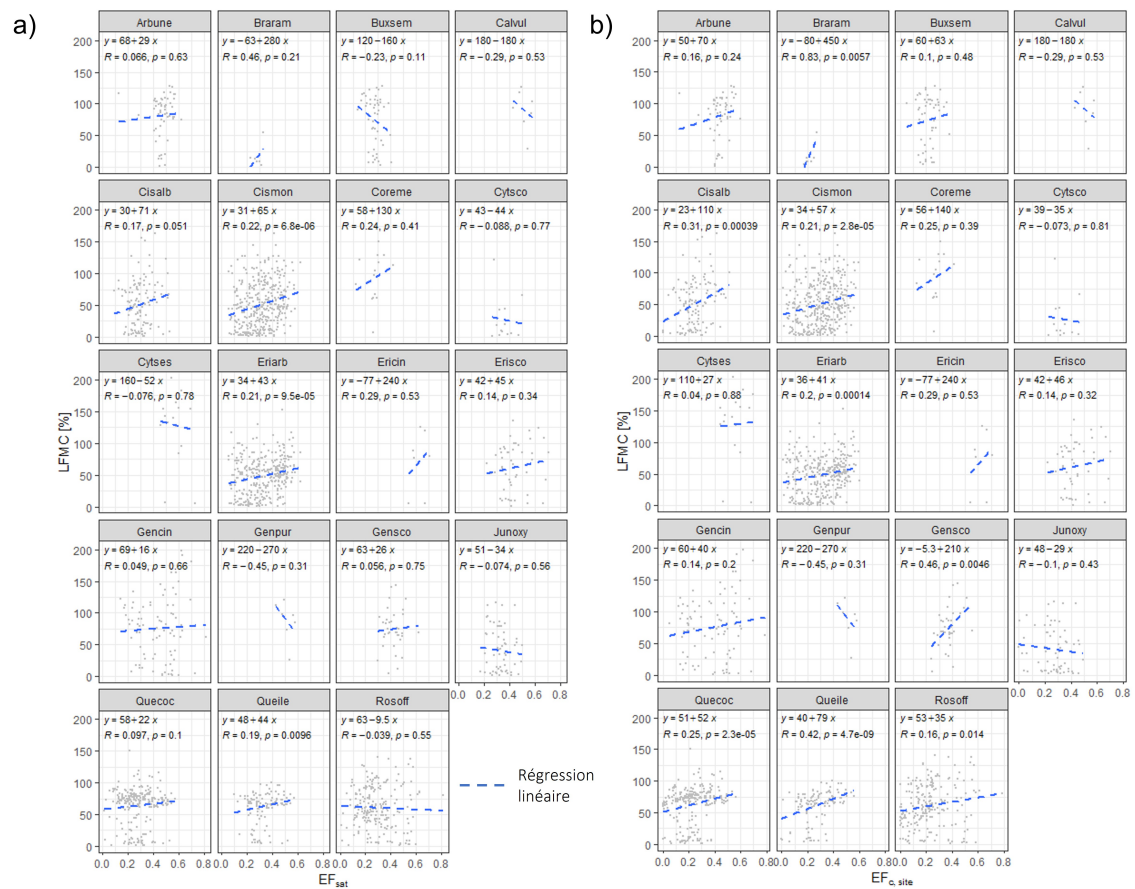


FIGURE A.3 – Nuage de points du $LFMC$ déduit des mesures sur le Réseau Hydrique entre 2015 et 2021 en fonction de EF estimée par la méthode $LST - f_{vg}$ (a) et de l'effet des ombres portées (b) par site.

Bibliographie

- Adams, J.B., Sabol, D.E., Kapos, V., Almeida Filho, R., Roberts, D.A., Smith, M.O., Gillespie, A.R., 1995. Classification of multispectral images based on fractions of endmembers : Application to land-cover change in the brazilian amazon. *Remote Sensing of Environment* 52, 137–154. doi :[https://doi.org/10.1016/0034-4257\(94\)00098-8](https://doi.org/10.1016/0034-4257(94)00098-8).
- Alexandrian, D., Esnault, F., Calabri, G., 1999. Forest fires in the mediterranean area. Food and Agriculture Organization of the United Nations .
- Allen, R.G., Pereira, L.S., Raes, D., Smith, M., 1998. Crop evapotranspiration - Guidelines for computing crop water requirements. FAO Irrigation and Drainage Paper 56, FAO - Food and Agriculture Organization of the United Nations, Rome.
- Amazirh, A., Merlin, O., Er-Raki, S., Gao, Q., Rivalland, V., Malbeteau, Y., Khabba, S., Escorihuela, M.J., 2018. Retrieving surface soil moisture at high spatio-temporal resolution from a synergy between sentinel-1 radar and landsat thermal data : A study case over bare soil. *Remote Sensing of Environment* 211, 321–337. doi :<https://doi.org/10.1016/j.rse.2018.04.013>.
- Amroussia, M., Viedma, O., Achour, H., Abbes, C., 2023. Predicting spatially explicit composite burn index (cbi) from different spectral indices derived from sentinel 2a : A case of study in tunisia. *Remote Sensing* 15, 335. doi :[10.3390/rs15020335](https://doi.org/10.3390/rs15020335).
- Anderson, M.C., Kustas, W.P., Norman, J.M., Hain, C.R., Mecikalski, J.R., Schultz, L., González-Dugo, M.P., Cammalleri, C., d'Urso, G., Pimstein, A., Gao, F., 2011. Mapping daily evapotranspiration at field to continental scales using geostationary and polar orbiting satellite imagery. *Hydrology and Earth System Sciences* 15, 223–239. doi :[10.5194/hess-15-223-2011](https://doi.org/10.5194/hess-15-223-2011).
- Anderson, M.C., Norman, J.M., Mecikalski, J.R., Otkin, J.A., Kustas, W.P., 2007. A climatological study of evapotranspiration and moisture stress across the continental united states based on thermal remote sensing : 1. model formulation. *Journal of Geophysical Research : Atmospheres* 112. doi :<https://doi.org/10.1029/2006JD007506>.
- Andrews, P.L., 1986. BEHAVE : fire behavior prediction and fuel modeling system : BURN subsystem, Part 1. volume 194. US Department of Agriculture, Forest Service, Intermountain Research Station.
- Andrews, P.L., 2018. The Rothermel surface fire spread model and associated developments : A comprehensive explanation. doi :[10.2737/rmrs-gtr-371](https://doi.org/10.2737/rmrs-gtr-371).
- Arroyo, L., Pascual, C., Manzanera, J., 2008. Fire models and methods to map fuel types : The role of remote sensing. *Forest Ecology and Management* 256, 1239–1252. doi :[10.1016/j.foreco.2008.06.048](https://doi.org/10.1016/j.foreco.2008.06.048).

- Bacci, J., Loisier, A., Martin, P., Rietmann, O., 2022. Rapport d'information fait au nom de la commission de l'aménagement du territoire et du développement durable et de la commission des affaires économiques par la mission conjointe de contrôle relative à la prévention et à la lutte contre l'intensification et l'extension du risque incendie. Technical Report. Sénat.
- Bachmann, A., Allgöwer, B., 2001. A consistent wildland fire risk terminology is needed! *Fire Management Today* 61, 28–33.
- Banerjee, T., De Roo, F., Mauder, M., 2017. Explaining the convective effect in canopy turbulence by means of large-eddy simulation. *Hydrology and Earth System Sciences* 21, 2987–3000. doi :10.5194/hess-21-2987-2017.
- Barbero, R., Curt, T., Ganteaume, A., Maillé, E., Jappiot, M., Bellet, A., 2019. Simulating the effects of weather and climate on large wildfires in france. *Natural Hazards and Earth System Sciences* 19, 441–454. doi :10.5194/nhess-19-441-2019.
- Bartkowiak, P., Ventura, B., Jacob, A., Castelli, M., 2024. A copernicus-based evapotranspiration dataset at 100 m spatial resolution over four mediterranean basins. *Earth System Science Data* 16, 4709–4734. doi :10.5194/essd-16-4709-2024.
- Bataineh, A.L., Oswald, B.P., Bataineh, M., Unger, D., Hung, I.K., Scognamillo, D., 2006. Spatial autocorrelation and pseudoreplication in fire ecology. *Fire Ecology* 2, 107–118. doi :10.4996/fireecology.0202107.
- Berry, J.A., Beerling, D.J., Franks, P.J., 2010. Stomata : key players in the earth system, past and present. *Current Opinion in Plant Biology* 13, 232–239. doi :https://doi.org/10.1016/j.pbi.2010.04.013.
- Bian, Z., Roujean, J.L., Cao, B., Du, Y., Li, H., Gamet, P., Fang, J., Xiao, Q., Liu, Q., 2021. Modeling the directional anisotropy of fine-scale fire emissions over tree and crop canopies based on uav measurements. *Remote Sensing of Environment* 252, 112150. doi :https://doi.org/10.1016/j.rse.2020.112150.
- Birch, D.S., Morgan, P., Kolden, C.A., Abatzoglou, J.T., Dillon, G.K., Hudak, A.T., Smith, A.M.S., 2015. Vegetation, topography and daily weather influenced burn severity in central idaho and western montana forests. *Ecosphere* 6, art17. doi :10.1890/ES14-00213.1.
- Boulet, G., Chehbouni, A., Gentine, P., Duchemin, B., Ezzahar, J., Hadria, R., 2007. Monitoring water stress using time series of observed to unstressed surface temperature difference. *Agricultural and Forest Meteorology* 146, 159–172. doi :https://doi.org/10.1016/j.agrformet.2007.05.012.
- Boulet, G., Mougnot, B., Lhomme, J.P., Fanise, P., Lili-Chabaane, Z., Oliosio, A., Bahir, M., Rivalland, V., Jarlan, L., Merlin, O., Coudert, B., Er-Raki, S., Lagouarde, J.P., 2015. The sparse model for the prediction of water stress and evapotranspiration components from thermal infra-red data and its evaluation over irrigated and rainfed wheat. *Hydrology and Earth System Sciences* 19, 4653–4672. doi :10.5194/hess-19-4653-2015.
- Bradshaw, L.S., Deeming, J.E., Burgan, R.E., Cohen, J.D., 1983. The 1978 National Fire-Danger Rating System : Technical Documentation. Technical Report INT-169. U.S. Department of Agriculture, Forest Service, Intermountain Forest and Range Experiment Station. Ogden, Utah.
- Bradstock, R.A., 2010. A biogeographic model of fire regimes in australia : current and future implications. *Global Ecology and Biogeography* 19, 145–158. doi :https://doi.org/10.1111/j.1466-8238.2009.00512.x.

- Brodrick, P.G., Asner, G.P., 2017. Remotely sensed predictors of conifer tree mortality during severe drought. *Environmental Research Letters* 12, 115013. doi :10.1088/1748-9326/aa8f55.
- Burchard-Levine, V., Nieto, H., Riaño, D., Kustas, W.P., Migliavacca, M., El-Madany, T.S., Nelson, J.A., Andreu, A., Carrara, A., Beringer, J., Baldocchi, D., Martín, M.P., 2022. A remote sensing-based three-source energy balance model to improve global estimations of evapotranspiration in semi-arid tree-grass ecosystems. *Global Change Biology* 28, 1493–1515. doi :https://doi.org/10.1111/gcb.16002.
- Burchard-Levine, V., Nieto, H., Riaño, D., Migliavacca, M., El-Madany, T.S., Guzinski, R., Carrara, A., Martín, M.P., 2021. The effect of pixel heterogeneity for remote sensing based retrievals of evapotranspiration in a semi-arid tree-grass ecosystem. *Remote Sensing of Environment* 260, 112440. doi :https://doi.org/10.1016/j.rse.2021.112440.
- Burgan, R.E., Klaver, R.W., Klaver, J.M., 1998. Fuel models and fire potential from satellite and surface observations. *International journal of wildland fire* 8, 159–170. doi :10.1071/WF9980159.
- Byram, G.M., 1959. Combustion of forest fuels. in 'forest fire : control and use'.(ed. kp davis) pp. 61–89.
- Canadian Forest Service Fire Danger Group, 1992. Development and Structure of the Canadian Forest Fire Behavior Prediction System. Canada Department of Forestry Science and Sustainable Development Directorate Information Report ST-X, Forestry Canada, Science and Sustainable Development Directorate.
- Canadian Forest Service Fire Danger Group, 2021. An overview of the next generation of the Canadian Forest Fire Danger Rating System. Information Report GLC-X-26. Natural Resources Canada, Canadian Forest Service, Great Lakes Forestry Centre.
- Cao, B., Bian, Z., Du, Y., Li, H., Xiao, Q., Liu, Q., 2019a. Evaluation of four kernel driven models in the thermal infrared band using airborne measured multi-angle datasets, in : IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium, pp. 6660–6663. doi :10.1109/IGARSS.2019.8898385.
- Cao, B., Liu, Q., Du, Y., Roujean, J.L., Gastellu-Etchegorry, J.P., Trigo, I.F., Zhan, W., Yu, Y., Cheng, J., Jacob, F., Lagouarde, J.P., Bian, Z., Li, H., Hu, T., Xiao, Q., 2019b. A review of earth surface thermal radiation directionality observing and modeling : Historical development, current status and perspectives. *Remote Sensing of Environment* 232, 111304. doi :https://doi.org/10.1016/j.rse.2019.111304.
- Carlson, T.N., 2020. A brief analysis of the triangle method and a proposal for its operational implementation. *Remote Sensing* 12. doi :10.3390/rs12223832.
- Ceccato, P., Flasse, S., Grégoire, J.M., 2002a. Designing a spectral index to estimate vegetation water content from remote sensing data : Part 2. validation and applications. *Remote Sensing of Environment* 82, 198–207. doi :https://doi.org/10.1016/S0034-4257(02)00036-6.
- Ceccato, P., Gobron, N., Flasse, S., Pinty, B., Tarantola, S., 2002b. Designing a spectral index to estimate vegetation water content from remote sensing data : Part 1 : Theoretical approach. *Remote Sensing of Environment* 82, 188–197. doi :https://doi.org/10.1016/S0034-4257(02)00037-8.
- Chaivaranont, W., Evans, J.P., Liu, Y.Y., Sharples, J.J., 2018. Estimating grassland curing with remotely sensed data. *Natural Hazards and Earth System Sciences* 18, 1535–1554. doi :10.5194/nhess-18-1535-2018.

- Chatry, C., Le Quentrec, M., Laurens, D., Le Gallou, J.Y., Lafitte, J.J., Creuchet, B., Grelu, J., 2010. Changement climatique et extension des zones sensibles aux feux de forêts. Rapport technique. Conseil général de l'environnement et du développement durable, Conseil général de l'alimentation, de l'agriculture et des espaces ruraux, Inspection générale des finances.
- Chirouze, J., Boulet, G., Jarlan, L., Fieuzal, R., Rodriguez, J.C., Ezzahar, J., Er-Raki, S., Bigeard, G., Merlin, O., Garatuza-Payan, J., Watts, C., Chehbouni, G., 2014. Intercomparison of four remote-sensing-based energy balance methods to retrieve surface evapotranspiration and water stress of irrigated fields in semi-arid climate. *Hydrology and Earth System Sciences* 18, 1165–1188. doi :10.5194/hess-18-1165-2014.
- Choudhury, B., Reginato, R., Idso, S., 1986. An analysis of infrared temperature observations over wheat and calculation of latent heat flux. *Agricultural and Forest Meteorology* 37, 75–88. doi :https://doi.org/10.1016/0168-1923(86)90029-8.
- Chuvienco, E., Cocero, D., no, D.R., Martin, P., Martínez-Vega, J., de la Riva, J., Pérez, F., 2004. Combining ndvi and surface temperature for the estimation of live fuel moisture content in forest fire danger rating. *Remote Sensing of Environment* 92, 322–331. doi :https://doi.org/10.1016/j.rse.2004.01.019. forest Fire Prevention and Assessment.
- Chuvienco, E., De Santis, A., Riaño, D., Halligan, K., 2007. Simulation approaches for burn severity estimation using remotely sensed images. *Fire Ecology* 3, 129–150. doi :10.4996/fireecology.0301129.
- Chuvienco, E., Deshayes, M., Stach, N., Cocero, D., Riaño, D., 1999. Short-term fire risk : foliage moisture content estimation from satellite data. pp. 17–38. doi :10.1007/978-3-642-60164-4_3.
- Chuvienco, E., Riaño, D., Aguado, I., Cocero, D., 2002. Estimation of fuel moisture content from multi-temporal analysis of landsat thematic mapper reflectance data : Applications in fire danger assessment. *International Journal of Remote Sensing* 23, 2145–2162. doi :10.1080/01431160110069818.
- Chuvienco, E., Riaño, D., Danson, F.M., Martin, P., 2006. Use of a radiative transfer model to simulate the postfire spectral response to burn severity. *Journal of Geophysical Research : Biogeosciences* 111, 15. doi :10.1029/2005JG000143.
- Chuvienco, E., Yebra, M., Martino, S., Thonicke, K., Gómez-Giménez, M., San-Miguel, J., Oom, D., Velea, R., Mouillot, F., Molina, J.R., Miranda, A.I., Lopes, D., Salis, M., Bugaric, M., Sofiev, M., Kadantsev, E., Gitas, I.Z., Stavrakoudis, D., Eftychidis, G., Bar-Massada, A., Neidermeier, A., Pampanoni, V., Pettinari, M.L., Arrogante-Funes, F., Ochoa, C., Moreira, B., Viegas, D., 2023. Towards an integrated approach to wildfire risk assessment : When, where, what and how may the landscapes burn. *Fire* 6. doi :10.3390/fire6050215.
- Collins, L., Bradstock, R.A., Penman, T.D., 2014. Can precipitation influence landscape controls on wildfire severity ? a case study within temperate eucalypt forests of south-eastern australia. *International Journal of Wildland Fire* 23, 9–20. doi :10.1071/WF12184.
- Collins, L., Griffioen, P., Newell, G., Mellor, A., 2018. The utility of random forests for wildfire severity mapping. *Remote Sensing of Environment* 216, 374–384. doi :https://doi.org/10.1016/j.rse.2018.07.005.

- Costa-Saura, J.M., Bacciu, V., Ribotta, C., Spano, D., Massaiu, A., Sirca, C., 2022. Predicting and mapping potential fire severity for risk analysis at regional level using google earth engine. *Remote Sensing* 14. doi :10.3390/rs14194812.
- Costes, A., 2021. Couplage bidirectionnel feu-atmosphère pour la propagation des incendies de forêt : modélisation, incertitudes et sensibilités. Theses. Université Paul Sabatier - Toulouse III.
- Cruz, M.G., Gould, J.S., Alexander, M.E., Sullivan, A.L., McCaw, W.L., Matthews, S., 2015. A Guide to Rate of Fire Spread Models for Australian Vegetation. CSIRO Land and Water Flagship, Canberra, and AFAC, Melbourne, Australia.
- Cunill Camprubí, A., González-Moreno, P., Resco de Dios, V., 2022. Live fuel moisture content mapping in the mediterranean basin using random forests and combining modis spectral and thermal data. *Remote Sensing* 14, 3162. doi :10.3390/rs14133162.
- De Santis, A., Asner, G.P., Vaughan, P.J., Knapp, D.E., 2010. Mapping burn severity and burning efficiency in california using simulation models and landsat imagery. *Remote Sensing of Environment* 114, 1535–1545. doi :10.1016/j.rse.2010.02.013.
- De Santis, A., Chuvieco, E., 2007. Burn severity estimation from remotely sensed data : Performance of simulation versus empirical models. *Remote Sensing of Environment* 108, 422–435. doi :<https://doi.org/10.1016/j.rse.2006.11.022>.
- De Santis, A., Chuvieco, E., Vaughan, P.J., 2009. Short-term assessment of burn severity using the inversion of prospect and geosail models. *Remote Sensing of Environment* 113, 126–136. doi :10.1016/j.rse.2008.08.008.
- Delogu, E., Boulet, G., Oliosio, A., Garrigues, S., Brut, A., Tallec, T., Demarty, J., Soudani, K., Lagouarde, J.P., 2018. Evaluation of the sparse dual-source model for predicting water stress and evapotranspiration from thermal infrared data over multiple crops and climates. *Remote Sensing* 10. doi :10.3390/rs10111806.
- DGSCGC, 2021. Guide de doctrine opérationnelle (GDO) : feux de forêts et d'espaces naturels. Guide technique.
- Dillon, G.K., Holden, Z.A., Morgan, P., Crimmins, M.A., Heyerdahl, E.K., Luce, C.H., 2011. Both topography and climate affected forest and woodland burn severity in two regions of the western us, 1984 to 2006. *Ecosphere* 2, art130. doi :10.1890/ES11-00271.1.
- Disney, M., Lewis, P., Gomez-Dans, J., Roy, D., Wooster, M., Lajas, D., 2011. 3d radiative transfer modelling of fire impacts on a two-layer savanna system. *Remote Sensing of Environment* 115, 1866–1881. doi :<https://doi.org/10.1016/j.rse.2011.03.010>.
- Duff, T.J., Bessell, R., Cruz, M.G., 2019. Grass curing/cured fuels, in : *Encyclopedia of Wildfires and Wildland-Urban Interface (WUI) Fires*. Springer. doi :10.1007/978-3-319-51727-8_238-1.
- Epting, J., Verbyla, D., Sorbel, B., 2005. Evaluation of remotely sensed indices for assessing burn severity in interior alaska using landsat tm and etm+. *Remote Sensing of Environment* 96, 328–339. doi :10.1016/j.rse.2005.03.002.
- Escuin, S., Navarro Cerrillo, R., Fernández, P., 2008. Fire severity assessment by using nbr (normalised burn ratio) and ndvi (normalised difference vegetation index) derived from landsat tm/etm images. *International Journal of Remote Sensing* 29, 1053–1073. doi :10.1080/01431160701281072.

- Estes, B.L., Knapp, E.E., Skinner, C.N., Miller, J.D., Preisler, H.K., 2017. Factors influencing fire severity under moderate burning conditions in the Klamath mountains, northern California, USA. *Ecosphere* 8, e01794. doi :10.1002/ecs2.1794.
- European Commission, 2025. European forest fire information system (EFFIS).
- Fan, L., Wigneron, J.P., Xiao, Q., Al-Yaari, A., Wen, J., Martin-StPaul, N., Dupuy, J.L., Pimont, F., Al Bitar, A., Fernandez-Moran, R., Kerr, Y., 2018. Evaluation of microwave remote sensing for monitoring live fuel moisture content in the Mediterranean region. *Remote Sensing of Environment* 205, 210–223. doi :<https://doi.org/10.1016/j.rse.2017.11.020>.
- Fang, L., Yang, J., White, M., Liu, Z., 2018. Predicting potential fire severity using vegetation, topography and surface moisture availability in a Eurasian boreal forest landscape. *Forests* 9. doi :10.3390/f9030130.
- Fang, L., Yang, J., Zu, J., Li, G., Zhang, J., 2015. Quantifying influences and relative importance of fire weather, topography, and vegetation on fire size and fire severity in a Chinese boreal forest landscape. *Forest Ecology and Management* 356, 2–12. doi :10.1016/j.foreco.2015.01.011. special Section : The characteristics, impacts and management of forest fire in China.
- Fargeon, H., 2019. Impact of climate change on future wildfire danger and activity in France. Theses. Institut agronomique, vétérinaire et forestier de France.
- Fearnside, P.M., de Alencastro Graça, P.M.L., Rodrigues, F.J.A., 2001. Burning of Amazonian rainforests : burning efficiency and charcoal formation in forest cleared for cattle pasture near Manaus, Brazil. *Forest Ecology and Management* 146, 115–128. doi :[https://doi.org/10.1016/S0378-1127\(00\)00450-3](https://doi.org/10.1016/S0378-1127(00)00450-3).
- Fernández-García, V., Beltrán-Marcos, D., Fernández-Guisuraga, J.M., Marcos, E., Calvo, L., 2022. Predicting potential wildfire severity across southern Europe with global data sources. *Science of The Total Environment* 829, 154729. doi :10.1016/j.scitotenv.2022.154729.
- Fernández-Guisuraga, J.M., Fernandes, P.M., 2023. Using pre-fire high point cloud density lidar data to predict fire severity in central Portugal. *Remote Sensing* 15. doi :10.3390/rs15030768.
- Fernández-Guisuraga, J.M., Fernandes, P.M., Marcos, E., Beltrán-Marcos, D., Sarricolea, P., Farris, M., Calvo, L., 2023. Caution is needed across Mediterranean ecosystems when interpreting wall-to-wall fire severity estimates based on spectral indices. *Forest Ecology and Management* 546, 121383. doi :<https://doi.org/10.1016/j.foreco.2023.121383>.
- Fox, D., Carrega, P., Ren, Y., Caillouet, P., Bouillon, C., Robert, S., 2018. How wildfire risk is related to urban planning and fire weather index in SE France (1990–2013). *Science of The Total Environment* 621, 120–129. doi :<https://doi.org/10.1016/j.scitotenv.2017.11.174>.
- Fox, D., Martin, N., Carrega, P., Andrieu, J., Adnès, C., Emsellem, K., Ganga, O., Moebius, F., Tortorollo, N., Fox, E., 2015. Increases in fire risk due to warmer summer temperatures and wildland urban interface changes do not necessarily lead to more fires. *Applied Geography* 56, 1–12. doi :<https://doi.org/10.1016/j.apgeog.2014.10.001>.
- Gale, M., Cary, G., 2022. What determines variation in remotely sensed fire severity? consideration of remote sensing limitations and confounding factors. *International Journal of Wildland Fire* 31, 291–305. doi :10.1071/WF21131.

- Gale, M.G., Cary, G.J., van Dijk, A.I., Yebra, M., 2023. Untangling fuel, weather and management effects on fire severity : Insights from large-sample lidar remote sensing analysis of conditions preceding the 2019-20 australian wildfires. *Journal of Environmental Management* 348, 119474. doi :<https://doi.org/10.1016/j.jenvman.2023.119474>.
- Gallego-Elvira, B., Oliosio, A., Mira, M., Reyes-Castillo, S., Boulet, G., Marloie, O., Garrigues, S., Courault, D., Weiss, M., Chauvelon, P., Boutron, O., 2013. Evaspa (evapotranspiration assessment from space) tool : An overview. *Procedia Environmental Sciences* 19, 303–310. doi :<https://doi.org/10.1016/j.proenv.2013.06.035>. four Decades of Progress in Monitoring and Modeling of Processes in the Soil-Plant-Atmosphere System : Applications and Challenges.
- García, M., Riaño, D., Yebra, M., Salas, J., Cardil, A., Monedero, S., Ramirez, J., Martín, M.P., Vilar, L., Gajardo, J., Ustin, S., 2020. A live fuel moisture content product from landsat tm satellite time series for implementation in fire behavior models. *Remote Sensing* 12. doi :[10.3390/rs12111714](https://doi.org/10.3390/rs12111714).
- García-Llamas, P., Suárez-Seoane, S., Fernández-Guisuraga, J.M., Fernández-García, V., Fernández-Manso, A., Quintano, C., Taboada, A., Marcos, E., Calvo, L., 2019. Evaluation and comparison of landsat 8, sentinel-2 and deimos-1 remote sensing indices for assessing burn severity in mediterranean fire-prone ecosystems. *International Journal of Applied Earth Observation and Geoinformation* 80, 137–144. doi :<https://doi.org/10.1016/j.jag.2019.04.006>.
- Gibson, R., Danaher, T., Hehir, W., Collins, L., 2020. A remote sensing approach to mapping fire severity in south-eastern australia using sentinel 2 and random forest. *Remote Sensing of Environment* 240, 111702. doi :<https://doi.org/10.1016/j.rse.2020.111702>.
- Gokmen, M., Vekerdy, Z., Verhoef, A., Verhoef, W., Batelaan, O., van der Tol, C., 2012. Integration of soil moisture in sebs for improving evapotranspiration estimation under water stress conditions. *Remote Sensing of Environment* 121, 261–274. doi :<https://doi.org/10.1016/j.rse.2012.02.003>.
- Gokool, S., Riddell, E., Jarmain, C., Chetty, K., Feig, G., Thenga, H., 2020. Evaluating the accuracy of satellite-derived evapotranspiration estimates acquired during conditions of water stress. *International Journal of Remote Sensing* 41, 704–724. doi :[10.1080/01431161.2019.1646940](https://doi.org/10.1080/01431161.2019.1646940).
- González-Dugo, M.P., Chen, X., Andreu, A., Carpintero, E., Gómez-Giraldez, P.J., Carrara, A., Su, Z., 2021. Long-term water stress and drought assessment of mediterranean oak savanna vegetation using thermal remote sensing. *Hydrology and Earth System Sciences* 25, 755–768. doi :[10.5194/hess-25-755-2021](https://doi.org/10.5194/hess-25-755-2021).
- González, M.E., Gómez-González, S., Lara, A., Garreaud, R., Díaz-Hormazábal, I., 2018. The 2010–2015 megadrought and its influence on the fire regime in central and south-central chile. *Ecosphere* 9, e02300. doi :[10.1002/ecs2.2300](https://doi.org/10.1002/ecs2.2300).
- González-Alonso, F., de Miguel, S.M., Roldán-Zamarrón, A., García-Gigorro, S., Gozalo, J.M.C., 2006. Forest biomass estimation through ndvi composites. the role of remotely sensed data to assess spanish forests as carbon sinks. *International Journal of Remote Sensing* 27, 5409–5415. doi :[10.1080/01431160600830748](https://doi.org/10.1080/01431160600830748).
- de Groot, W.J., 1987. Interpreting the canadian forest fire weather index (fwi) system, in : *Fourth Central Regional Fire Weather Committee Scientific and Technical Seminar.*, pp. 3–14.

- Guillevic, P., Bork-Unkelbach, A., Göttsche, F.M., Hulley, G., Gastellu-Etchegorry, J.P., Olesen, F.S., Privette, J.L., 2013. Directional viewing effects on satellite land surface temperature products over sparse vegetation canopies—a multisensor analysis. *IEEE Geoscience and Remote Sensing Letters* 10, 1464–1468. doi :10.1109/LGRS.2013.2260319.
- Guillevic, P., Gastellu-Etchegorry, J.P., Demarty, J., Prévot, L., 2003. Thermal infrared radiative transfer within three-dimensional vegetation covers. *Journal of Geophysical Research : Atmospheres* 108. doi :https://doi.org/10.1029/2002JD002247.
- Holden, Z.A., Morgan, P., Evans, J.S., 2009. A predictive model of burn severity based on 20-year satellite-inferred burn severity data in a large southwestern us wilderness area. *Forest Ecology and Management* 258, 2399–2406. doi :10.1016/j.foreco.2009.08.017.
- Hollis, J.J., Matthews, S., Fox-Hughes, P., Grootemaat, S., Heemstra, S., Kenny, B.J., Sauvage, S., 2024. Introduction to the australian fire danger rating system. *International Journal of Wildland Fire* 33, WF23140. doi :10.1071/WF23140.
- Holz, A., Kitzberger, T., Paritsis, J., Veblen, T.T., 2012. Ecological and climatic controls of modern wildfire activity patterns across southwestern south america. *Ecosphere* 3, art103. doi :10.1890/ES12-00234.1.
- Hoy, E.E., French, N.H., Turetsky, M.R., Trigg, S.N., Kasischke, E.S., 2008. Evaluating the potential of landsat tm/etm+ imagery for assessing fire severity in alaskan black spruce forests. *International Journal of Wildland Fire* 17, 500–514. doi :10.1071/WF08107.
- Hu, T., Mallick, K., Hitzelberger, P., Didry, Y., Boulet, G., Szantoi, Z., Koetz, B., Alonso, I., Pascolini-Campbell, M., Halverson, G., Cawse-Nicholson, K., Hulley, G., Hook, S., Bhattarai, N., Oliosio, A., Roujean, J.L.C.H., Gamet, P., Su, Z.B., 2023. Evaluating European ECOSTRESS Hub Evapotranspiration Products Retrieved from Three Structurally Contrasting SEB Models over Europe. *Water Resources Research* doi :10.1029/2022WR034132.
- Hudak, A., Morgan, P., Bobbitt, M., Lentile, L., 2007a. Characterizing stand- replacing harvest and fire disturbance patches in a forested landscape : A case study from cooney ridge, montana , 209–231doi :10.1201/9781420005189.ch8.
- Hudak, A., Morgan, P., Bobbitt, M., Smith, A., Lewis, S., Lentile, L., Robichaud, P., Clark, J., McKinley, R., 2007b. The relationship of multispectral satellite imagery to immediate fire effects. *Fire Ecology* 3, 64–90. doi :10.4996/fireecology.0301064.
- IGN, 2024. Lidar h.d. | géoservices [www document]. <https://geoservices.ign.fr/lidarhd#telechargementclassifiees> [accessed 10.04.24].
- IGN-IFN, 2024. Mémento 2024 de l'inventaire forestier national. <https://www.ign.fr/espace-presse/memento-2024>[accessed 10.02.25].
- IGN-IFN, 2025. Les incendies de forêt et de végétation. <https://foret.ign.fr/themes/les-incendies-de-foret-et-de-vegetation>[accessed 10.02.25].
- Jain, T.B., Graham, R.T., 2004. Is forest structure related to fire severity? yes, no, and maybe : Methods and insights in quantifying the answer, in : *Silviculture in Special Places : Proceedings of the 2003 National Silviculture Workshop*, U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station. pp. 217–234.

- Jain, T.B., Graham, R.T., 2007. The relation between tree burn severity and forest structure in the rocky mountains, in : Restoring fire-adapted ecosystems : Proceedings of the 2005 national silviculture workshop. Tahoe City, CA. Albany, CA. USDA Forest Service. Pacific Southwest Research Station, pp. 213–250.
- Jaleel, C., Manivannan, P., Wahid, A., Farooq, M., Somasundaram, R., Panneerselvam, R., 2009. Drought stress in plants : a review on morphological characteristics and pigments composition. *International Journal of Agriculture and Biology* 11, 100–105.
- Jensen, H., Jensen, K., Rosbjerg, D., 1991. Plant water relationships and evapotranspiration, in : Hydrological Interactions Between Atmosphere, Soil and Vegetation, International Association of Hydrological Sciences, Vienna.
- Jiang, L., Islam, S., 1999. A methodology for estimation of surface evapotranspiration over large areas using remote sensing observations. *Geophysical Research Letters* 26, 2773–2776. doi :<https://doi.org/10.1029/1999GL006049>.
- Jin, Y., Randerson, J.T., Faivre, N., Capps, S., Hall, A., Goulden, M.L., 2014. Contrasting controls on wildland fires in southern california during periods with and without santa ana winds. *Journal of Geophysical Research : Biogeosciences* 119, 432–450. doi :<https://doi.org/10.1002/2013JG002541>.
- Jolly, W.M., Freeborn, P.H., Bradshaw, L.S., Wallace, J., Brittain, S., 2024. Modernizing the us national fire danger rating system (version 4) : Simplified fuel models and improved live and dead fuel moisture calculations. *Environmental Modelling & Software* 181, 106181. doi :[10.1016/j.envsoft.2024.106181](https://doi.org/10.1016/j.envsoft.2024.106181).
- Jones, H.G., Rotenberg, E., 2011. *Energy, Radiation and Temperature Regulation in Plants*. John Wiley & Sons, Ltd. doi :<https://doi.org/10.1002/9780470015902.a0003199.pub2>.
- Kadivar, M., Tormey, D., McGranaghan, G., 2021. A review on turbulent flow over rough surfaces : Fundamentals and theories. *International Journal of Thermofluids* 10, 100077. doi :<https://doi.org/10.1016/j.ijft.2021.100077>.
- Kane, V.R., Cansler, C.A., Povak, N.A., Kane, J.T., McGaughey, R.J., Lutz, J.A., Churchill, D.J., North, M.P., 2015. Mixed severity fire effects within the rim fire : Relative importance of local climate, fire weather, topography, and forest structure. *Forest Ecology and Management* 358, 62–79. doi :<https://doi.org/10.1016/j.foreco.2015.09.001>.
- Kang, Z., Quan, X., Lai, G., 2023. Assessing the effects of fuel moisture content on the 2018 megafires in california. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 16, 868–877. doi :[10.1109/JSTARS.2022.3232665](https://doi.org/10.1109/JSTARS.2022.3232665).
- Keeley, J., 2009. Fire intensity, fire severity and burn severity : A brief review and suggested usage. *International Journal of Wildland Fire* 18, 116–126. doi :[10.1071/WF07049](https://doi.org/10.1071/WF07049).
- Key, C.H., Benson, N.C., 2003. The normalized burn ratio (NBR) : A Landsat TM radiometric measure of burn severity. Technical Report. US Geological Survey Northern Rocky Mountain Science Center. U.S. Department of the Interior, U.S. Geological Survey, Northern Rocky Mountain Science Center.
- Key, C.H., Benson, N.C., 2005. Landscape Assessment (LA) Sampling and Analysis Methods *in* Lutes, Duncan C. ; Keane, Robert E. ; Caratti, John F. ; Key, Carl H. ; Benson, Nathan C. ; Sutherland, Steve ;

- Gangi, Larry J. 2006. FIREMON : Fire effects monitoring and inventory system. Gen. Tech. Rep. RMRS-GTR-164-CD. Fort Collins, CO : U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station. pp. LA 1–51.
- Khan, M.S., Jeong, J., Choi, M., 2021. An improved remote sensing based approach for predicting actual evapotranspiration by integrating lidar. *Advances in Space Research* 68, 1732–1753. doi :<https://doi.org/10.1016/j.asr.2021.04.017>.
- Kokaly, R.F., Rockwell, B.W., Haire, S.L., King, T.V., 2007. Characterization of post-fire surface cover, soils, and burn severity at the cerro grande fire, new mexico, using hyperspectral and multispectral remote sensing. *Remote Sensing of Environment* 106, 305–325. doi :10.1016/j.rse.2006.08.006.
- Kustas, W.P., Anderson, M.C., Norman, J.M., Li, F., 2007. Utility of radiometric–aerodynamic temperature relations for heat flux estimation. *Boundary-Layer Meteorology* 122, 167–187. doi :10.1007/s10546-006-9093-1.
- Kustas, W.P., Daughtry, C.S., 1990. Estimation of the soil heat flux/net radiation ratio from spectral data. *Agricultural and Forest Meteorology* 49, 205–223. doi :[https://doi.org/10.1016/0168-1923\(90\)90033-3](https://doi.org/10.1016/0168-1923(90)90033-3).
- Labenski, P., Ewald, M., Schmidlein, S., Heinsch, F.A., Fassnacht, F.E., 2023. Quantifying surface fuels for fire modelling in temperate forests using airborne lidar and sentinel-2 : potential and limitations. *Remote Sensing of Environment* 295, 113711. doi :<https://doi.org/10.1016/j.rse.2023.113711>.
- Lecina-Diaz, J., Alvarez, A., Retana, J., 2014. Extreme fire severity patterns in topographic, convective and wind-driven historical wildfires of mediterranean pine forests. *PloS one* 9, e85127. doi :10.1371/journal.pone.0085127.
- Lentile, L.B., Smith, A.M.S., Hudak, A.T., Morgan, P., Bobbitt, M.J., Lewis, S.A., Robichaud, P.R., 2009. Remote sensing for prediction of 1-year post-fire ecosystem condition. *International Journal of Wildland Fire* 18, 594–608. doi :10.1071/WF07091.
- Leuning, R., Kelliher, F.M., De Pury, D.G.G., Schulze, E.D., 1995. Leaf nitrogen, photosynthesis, conductance and transpiration : scaling from leaves to canopies. *Plant, Cell & Environment* 18, 1183–1200. doi :<https://doi.org/10.1111/j.1365-3040.1995.tb00628.x>.
- Lewis, S.A., Robichaud, P.R., Hudak, A.T., Strand, E.K., Eitel, J.U.H., Brown, R.E., 2021. Evaluating the persistence of post-wildfire ash : A multi-platform spatiotemporal analysis. *Fire* 4. doi :10.3390/fire4040068.
- Limousin, J.M., 2009. Vulnérabilité du chêne vert (*Quercus ilex* L.) à une augmentation de la sécheresse : quels ajustements fonctionnels? Thèse. Montpellier SupAgro.
- Limousin, J.M., Roussel, A., Rodríguez-Calcerrada, J., Torres-Ruiz, J.M., Moreno, M., Garcia de Jalon, L., Ourcival, J.M., Simioni, G., Cochard, H., Martin-StPaul, N., 2022. Drought acclimation of quercus ilex leaves improves tolerance to moderate drought but not resistance to severe water stress. *Plant, Cell & Environment* 45, 1967–1984. doi :<https://doi.org/10.1111/pce.14326>.
- Littell, J.S., Peterson, D.L., Riley, K.L., Liu, Y., Luce, C.H., 2016. A review of the relationships between drought and forest fire in the united states. *Global Change Biology* 22, 2353–2369. doi :<https://doi.org/10.1111/gcb.13275>.

- Little, K., Graham, L.J., Flannigan, M., Belcher, C.M., Kettridge, N., 2024. Landscape controls on fuel moisture variability in fire-prone heathland and peatland landscapes. *Fire Ecology* 20, 14. doi :10.1186/s42408-024-00248-0.
- Liu, X., Xu, J., Zhou, X., Wang, W., Yang, S., 2020. Evaporative fraction and its application in estimating daily evapotranspiration of water-saving irrigated rice field. *Journal of Hydrology* 584, 124317. doi :<https://doi.org/10.1016/j.jhydro1.2019.124317>.
- Liu, Y., Guo, W., Song, Y., 2016. Estimation of key surface parameters in semi-arid region and their impacts on improvement of surface fluxes simulation. *Science China Earth Sciences* 59, 307–319. doi :10.1007/s11430-015-5140-4.
- Long, D., Singh, V.P., 2012. A two-source trapezoid model for evapotranspiration (ttme) from satellite imagery. *Remote Sensing of Environment* 121, 370–388. doi :<https://doi.org/10.1016/j.rse.2012.02.015>.
- Long, D., Singh, V.P., Scanlon, B.R., 2012. Deriving theoretical boundaries to address scale dependencies of triangle models for evapotranspiration estimation. *Journal of Geophysical Research : Atmospheres* 117. doi :<https://doi.org/10.1029/2011JD017079>.
- López García, M.J., Caselles, V., 1991. Mapping burns and natural reforestation using thematic mapper data. *Geocarto International* 6, 31–37. doi :10.1080/10106049109354290.
- Luquet, D., Vidal, A., Dauzat, J., Bégué, A., Olioso, A., Clouvel, P., 2004. Using directional tir measurements and 3d simulations to assess the limitations and opportunities of water stress indices. *Remote Sensing of Environment* 90, 53–62. doi :<https://doi.org/10.1016/j.rse.2003.09.008>.
- Lutes, D.C., Keane, R.E., Caratti, J.F., Key, C.H., Benson, N.C., Sutherland, S., Gangi, L.J., 2006. FIREMON : Fire Effects Monitoring and Inventory System. General Technical Report RMRS-GTR-164, U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station. doi :10.2737/RMRS-GTR-164.
- Maffei, C., Menenti, M., 2019. Predicting forest fires burned area and rate of spread from pre-fire multispectral satellite measurements. *ISPRS Journal of Photogrammetry and Remote Sensing* 158, 263–278. doi :10.1016/j.isprsjprs.2019.10.013.
- Malbêteau, Y., Merlin, O., Gascoin, S., Gastellu, J., Mattar, C., Olivera-Guerra, L., Khabba, S., Jarlan, L., 2017. Normalizing land surface temperature data for elevation and illumination effects in mountainous areas : A case study using aster data over a steep-sided valley in morocco. *Remote Sensing of Environment* 189, 25–39. doi :<https://doi.org/10.1016/j.rse.2016.11.010>.
- Malhi, R.K.M., Srivastava, P.K., Kiran, G.S., 2020. 6 - identification of functionally distinct plants using linear spectral mixture analysis, in : Pandey, P.C., Srivastava, P.K., Balzter, H., Bhattacharya, B., Petropoulos, G.P. (Eds.), *Hyperspectral Remote Sensing*. Elsevier. Earth Observation, pp. 95–106. doi :<https://doi.org/10.1016/B978-0-08-102894-0.00008-5>.
- Mallick, K., Boegh, E., Trebs, I., Alfieri, J.G., Kustas, W.P., Prueger, J.H., Niyogi, D., Das, N., Drewry, D.T., Hoffmann, L., Jarvis, A.J., 2015. Reintroducing radiometric surface temperature into the penman-monteith formulation. *Water Resources Research* 51, 6214–6243. doi :10.1002/2014WR016106.

- Mallick, K., Jarvis, A.J., Boegh, E., Fisher, J.B., Drewry, D.T., Tu, K.P., Hook, S.J., Hulley, G., Ardö, J., Beringer, J., Arain, A., Niyogi, D., 2014. A surface temperature initiated closure (stic) for surface energy balance fluxes. *Remote Sensing of Environment* 141, 243–261. doi :<https://doi.org/10.1016/j.rse.2013.10.022>.
- Marino, E., Yebra, M., Guillén-Climent, M., Algeet, N., Tomé, J.L., Madrigal, J., Guijarro, M., Hernando, C., 2020. Investigating live fuel moisture content estimation in fire-prone shrubland from remote sensing using empirical modelling and rtm simulations. *Remote Sensing* 12. doi :[10.3390/rs12142251](https://doi.org/10.3390/rs12142251).
- Marion, G.M., Moreno, J.M., Oechel, W.C., 1991. Fire severity, ash deposition, and clipping effects on soil nutrients in chaparral. *Soil Science Society of America Journal* 55, 235–240. doi :<https://doi.org/10.2136/sssaj1991.03615995005500010040x>.
- Martin-Ducup, O., Dupuy, J.L., Soma, M., Guerra-Hernandez, J., Marino, E., Fernandes, P.M., Just, A., Corbera, J., Touthkov, M., Sorribas, C., Bock, J., Piboule, A., Pirotti, F., Pimont, F., 2025. Unlocking the potential of airborne lidar for direct assessment of fuel bulk density and load distributions for wildfire hazard mapping. *Agricultural and Forest Meteorology* 362, 110341. doi :<https://doi.org/10.1016/j.agrformet.2024.110341>.
- Martin-StPaul, N., Pimont, F., Dupuy, J.L., Ruffault, J., Barbero, R., Fargeon, H., Guijarro, M., Hernando, C., Madrigal, J., Marino, E., Vélez, R., 2018. Live fuel moisture content (lfmc) time series for multiple sites and species in the french mediterranean area since 1996. *Annals of Forest Science* 75, 57. doi :[10.1007/s13595-018-0729-3](https://doi.org/10.1007/s13595-018-0729-3).
- Maurer, K.D., Bohrer, G., Kenny, W.T., Ivanov, V.Y., 2015. Large-eddy simulations of surface roughness parameter sensitivity to canopy-structure characteristics. *Biogeosciences* 12, 2533–2548. doi :[10.5194/bg-12-2533-2015](https://doi.org/10.5194/bg-12-2533-2015).
- McFarland, J.R., Coop, J.D., Balik, J.A., Rodman, K.C., Parks, S.A., Stevens-Rumann, C.S., 2025. Extreme fire spread events burn more severely and homogenize postfire landscapes in the southwestern united states. *Global Change Biology* 31, e70106. doi :<https://doi.org/10.1111/gcb.70106>. e70106 GCB-24-2625.R1.
- Meier, R., Davin, E.L., Bonan, G.B., Lawrence, D.M., Hu, X., Duveiller, G., Prigent, C., Seneviratne, S.I., 2022. Impacts of a revised surface roughness parameterization in the community land model 5.1. *Geoscientific Model Development* 15, 2365–2393. doi :[10.5194/gmd-15-2365-2022](https://doi.org/10.5194/gmd-15-2365-2022).
- Merlin, O., 2013. An original interpretation of the wet edge of the surface temperature–albedo space to estimate crop evapotranspiration (seb-1s), and its validation over an irrigated area in northwestern mexico. *Hydrology and Earth System Sciences* 17, 3623–3637. doi :[10.5194/hess-17-3623-2013](https://doi.org/10.5194/hess-17-3623-2013).
- Michel, J., Hagolle, O., Hook, S.J., Roujean, J.L., Gamet, P., 2023. Quantifying thermal infra-red directional anisotropy using master and landsat-8 simultaneous acquisitions. *Remote Sensing of Environment* 297, 113765. doi :<https://doi.org/10.1016/j.rse.2023.113765>.
- Miller, C., Harvey, B., Kane, V., Moskal, L., Alvarado, E., 2023. Different approaches make comparing studies of burn severity challenging : a review of methods used to link remotely sensed data with the composite burn index. *International Journal of Wildland Fire* 32, 449–475. doi :[10.1071/WF22050](https://doi.org/10.1071/WF22050).
- Miller, J., Thode, A., 2007. Quantifying burn severity in a heterogeneous landscape with a relative version of the delta normalized burn ratio (rdnbr). *Remote Sensing of Environment* 109, 66–80. doi :[10.1016/j.rse.2006.12.006](https://doi.org/10.1016/j.rse.2006.12.006).

- Miller, J., Yool, S., 2002. Mapping forest post-fire canopy consumption in several overstory types using multi-temporal landsat tm and etm data. *Remote Sensing of Environment* 82, 481–496. doi :10.1016/S0034-4257(02)00071-8.
- Monteith, J.L., 1965. Evaporation and environment, in : Fogg, G.E. (Ed.), *The State and Movement of Water in Living Organisms*. Academic Press, New York. volume 19, pp. 205–234.
- Moran, M., Clarke, T., Inoue, Y., Vidal, A., 1994. Estimating crop water deficit using the relation between surface-air temperature and spectral vegetation index. *Remote Sensing of Environment* 49, 246–263. doi :[https://doi.org/10.1016/0034-4257\(94\)90020-5](https://doi.org/10.1016/0034-4257(94)90020-5).
- Morillas, L., García, M., Nieto, H., Villagarcía, L., Sandholt, I., Gonzalez-Dugo, M., Zarco-Tejada, P., Domingo, F., 2013. Using radiometric surface temperature for surface energy flux estimation in mediterranean drylands from a two-source perspective. *Remote Sensing of Environment* 136, 234–246. doi :<https://doi.org/10.1016/j.rse.2013.05.010>.
- Mwangi, S., Boulet, G., Olioso, A., 2022. Assessment of an extended sparse model for estimating evapotranspiration from directional thermal infrared data. *Agricultural and Forest Meteorology* 317, 108882. doi :<https://doi.org/10.1016/j.agrformet.2022.108882>.
- Newnham, G.J., Verbesselt, J., Grant, I.F., Anderson, S.A., 2011. Relative greenness index for assessing curing of grassland fuel. *Remote Sensing of Environment* 115, 1456–1463. doi :<https://doi.org/10.1016/j.rse.2011.02.005>.
- Njuki, S.M., Mannaerts, C.M., Su, Z., 2023. Accounting for turbulence-induced canopy heat transfer in the simulation of sensible heat flux in sebs model. *Remote Sensing* 15. doi :10.3390/rs15061578.
- Nolan, R.H., Blackman, C.J., de Dios, V.R., Choat, B., Medlyn, B.E., Li, X., Bradstock, R.A., Boer, M.M., 2020. Linking forest flammability and plant vulnerability to drought. *Forests* 11. doi :10.3390/f11070779.
- Nolan, R.H., Foster, B., Griebel, A., Choat, B., Medlyn, B.E., Yebra, M., Younes, N., Boer, M.M., 2022. Drought-related leaf functional traits control spatial and temporal dynamics of live fuel moisture content. *Agricultural and Forest Meteorology* 319, 108941. doi :<https://doi.org/10.1016/j.agrformet.2022.108941>.
- Odion, D.C., Moritz, M.A., DellaSala, D.A., 2010. Alternative community states maintained by fire in the klamath mountains, usa. *Journal of Ecology* 98, 96–105. doi :<https://doi.org/10.1111/j.1365-2745.2009.01597.x>.
- Ollivier, C., Olioso, A., Carrière, S.D., Boulet, G., Chalikakis, K., Chanzy, A., Charlier, J.B., Combemale, D., Davi, H., Emblanch, C., Marloie, O., Martin-StPaul, N., Mazzilli, N., Simioni, G., Weiss, M., 2021. An evapotranspiration model driven by remote sensing data for assessing groundwater resource in karst watershed. *Science of The Total Environment* 781, 146706. doi :<https://doi.org/10.1016/j.scitotenv.2021.146706>.
- Parks, S.A., Dillon, G.K., Miller, C., 2014a. A new metric for quantifying burn severity : The relativized burn ratio. *Remote Sensing* 6, 1827–1844. doi :10.3390/rs6031827.
- Parks, S.A., Holsinger, L.M., Koontz, M.J., Collins, L., Whitman, E., Parisien, M.A., Loehman, R.A., Barnes, J.L., Bourdon, J.F., Boucher, J., Boucher, Y., Caprio, A.C., Collingwood, A., Hall, R.J.,

- Park, J., Saperstein, L.B., Smetanka, C., Smith, R.J., Soverel, N., 2019. Giving ecological meaning to satellite-derived fire severity metrics across north american forests. *Remote Sensing* 11. doi :10.3390/rs11141735.
- Parks, S.A., Holsinger, L.M., Panunto, M.H., Jolly, W.M., Dobrowski, S.Z., Dillon, G.K., 2018a. High-severity fire : evaluating its key drivers and mapping its probability across western us forests. *Environmental Research Letters* 13, 044037. doi :10.1088/1748-9326/aab791.
- Parks, S.A., Holsinger, L.M., Voss, M.A., Loehman, R.A., Robinson, N.P., 2018b. Correction : Parks et al. mean composite fire severity metrics computed with google earth engine offer improved accuracy and expanded mapping potential. *remote sens.* 2018, 10, 879. *Remote Sensing* 13. doi :10.3390/rs13224580.
- Parks, S.A., Parisien, M.A., Miller, C., Dobrowski, S., 2014b. Fire activity and severity in the western us vary along proxy gradients representing fuel amount and fuel moisture. *PloS one* 9, e99699. doi :10.1371/journal.pone.0099699.
- Pascolini-Campbell, M., Lee, C., Stavros, N., Fisher, J.B., 2022. Ecostress reveals pre-fire vegetation controls on burn severity for southern california wildfires of 2020. *Global Ecology and Biogeography* 31, 1976–1989. doi :10.1111/geb.13526.
- Pastor, E., Zárate, L., Planas, E., Arnaldos, J., 2003. Mathematical models and calculation systems for the study of wildland fire behaviour. *Progress in Energy and Combustion Science* 29, 139–153. doi :[https://doi.org/10.1016/S0360-1285\(03\)00017-0](https://doi.org/10.1016/S0360-1285(03)00017-0).
- Pausas, J.G., Keeley, J.E., Schwilk, D.W., 2017. Flammability as an ecological and evolutionary driver. *Journal of Ecology* 105, 289–297. doi :<https://doi.org/10.1111/1365-2745.12691>.
- Pellizzaro, G., Cesaraccio, C., Duce, P., Ventura, A., Zara, P., 2007. Relationships between seasonal patterns of live fuel moisture and meteorological drought indices for mediterranean shrubland species. *International Journal of Wildland Fire* 16, 232–241. doi :10.1071/WF06081.
- Penman, H.L., Keen, B.A., 1948. Natural evaporation from open water, bare soil and grass. *Proceedings of the Royal Society of London. Series A. Mathematical and Physical Sciences* 193, 120–145. doi :10.1098/rspa.1948.0037.
- Penot, V., Merlin, O., 2023. Estimating the water deficit index of a mediterranean holm oak forest from landsat optical/thermal data : A phenomenological correction for trees casting shadow effects. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 16, 5867–5880. doi :10.1109/JSTARS.2023.3288360.
- Pereira, J.M., Mota, B., Privette, J.L., Caylor, K.K., Silva, J.M., Sá, A.C., Ni-Meister, W., 2004. A simulation analysis of the detectability of understory burns in miombo woodlands. *Remote Sensing of Environment* 93, 296–310. doi :<https://doi.org/10.1016/j.rse.2004.01.009>.
- Perrakis, D.D.B., Cruz, M.G., Alexander, M.E., Hanes, C.C., Thompson, D.K., Taylor, S.W., Stocks, B.J., 2023. Improved logistic models of crown fire probability in canadian conifer forests. *International Journal of Wildland Fire* 32, 1455–1473. doi :10.1071/WF23074.
- Pesaresi, S., Mancini, A., Quattrini, G., Casavecchia, S., 2022. Functional analysis for habitat mapping in a special area of conservation using sentinel-2 time-series data. *Remote Sensing* 14. doi :10.3390/rs14051179.

- Pettorelli, N., Vik, J.O., Mysterud, A., Gaillard, J.M., Tucker, C., Stenseth, N.C., 2005. Using the satellite-derived ndvi to assess ecological responses to environmental change. *Trends in ecology & evolution* 20, 503–10. doi :10.1016/j.tree.2005.05.011.
- Pfoch, K.A., Pflugmacher, D., Okujeni, A., Hostert, P., 2023. Mapping forest fire severity using bi-temporal unmixing of sentinel-2 data - towards a quantitative understanding of fire impacts. *Science of Remote Sensing* 8, 100097. doi :10.1016/j.srs.2023.100097.
- Piedallu, C., Chéret, V., Denux, J., Perez, V., Azcona, J., Seynave, I., Gégout, J., 2019. Soil and climate differently impact ndvi patterns according to the season and the stand type. *Science of The Total Environment* 651, 2874–2885. doi :10.1016/j.scitotenv.2018.10.052.
- Pimont, F., Dupuy, J.L., Ruffault, J., Rigolot, E., Opitz, T., Legrand, J., Barbero, R., 2023. Projections des effets du changement climatique sur l'activité des feux de forêt au 21ème siècle : Rapport final. Technical Report. INRAE. doi :10.17180/gpdj-xb05. rapport réalisé dans le cadre de la convention MAA-INRAE du 9 mai 2022, n°G 03 / 2022.
- Pimont, F., Fargeon, H., Opitz, T., Ruffault, J., Barbero, R., Martin-StPaul, N., Rigolot, E., RiviÈre, M., Dupuy, J.L., 2021. Prediction of regional wildfire activity in the probabilistic bayesian framework of firelihood. *Ecological Applications* 31, e02316. doi :10.1002/eap.2316.
- Pimont, F., Ruffault, D., Martin-StPaul, N., Dupuy, J.L., 2019. Why is the effect of live fuel moisture content on fire rate of spread underestimated in field experiments in shrublands? *International Journal of Wildland Fire* 28, 127 – 137. doi :10.1071/WF18091.
- Pinheiro, A., Privette, J., Guillevic, P., 2006. Modeling the observed angular anisotropy of land surface temperature in a savanna. *IEEE Transactions on Geoscience and Remote Sensing* 44, 1036–1047. doi :10.1109/TGRS.2005.863827.
- Potapov, P., Li, X., Hernandez-Serna, A., Tyukavina, A., Hansen, M.C., Kommareddy, A., Pickens, A., Turbanova, S., Tang, H., Silva, C.E., Armston, J., Dubayah, R., Blair, J.B., Hofton, M., 2021. Mapping global forest canopy height through integration of gedi and landsat data. *Remote Sensing of Environment* 253, 112165. doi :https://doi.org/10.1016/j.rse.2020.112165.
- Prata, A.J., Caselles, V., Coll, C., Sobrino, J.A., Ottlé, C., 1995. Thermal remote sensing of land surface temperature from satellites : Current status and future prospects. *Remote Sensing Reviews* 12, 175–224. doi :10.1080/02757259509532285.
- Price, O.F., Bradstock, R.A., 2012. The efficacy of fuel treatment in mitigating property loss during wildfires : Insights from analysis of the severity of the catastrophic fires in 2009 in victoria, australia. *Journal of Environmental Management* 113, 146–157. doi :https://doi.org/10.1016/j.jenvman.2012.08.041.
- Quintano, C., Fernandez-Manso, A., Roberts, D.A., 2017. Burn severity mapping from landsat mesma fraction images and land surface temperature. *Remote Sensing of Environment* 190, 83–95. doi :https://doi.org/10.1016/j.rse.2016.12.009.
- Quintano, C., Fernández-Manso, A., Roberts, D.A., 2013. Multiple endmember spectral mixture analysis (mesma) to map burn severity levels from landsat images in mediterranean countries. *Remote Sensing of Environment* 136, 76–88. doi :https://doi.org/10.1016/j.rse.2013.04.017.

- Rambal, S., Ourcival, J.M., Joffre, R., Mouillot, F., Nouvellon, Y., Reichstein, M., Rocheteau, A., 2003. Drought controls over conductance and assimilation of a mediterranean evergreen ecosystem : scaling from leaf to canopy. *Global Change Biology* 9, 1813–1824. doi :<https://doi.org/10.1111/j.1365-2486.2003.00687.x>.
- Rao, K., Williams, A.P., Flefil, J.F., Konings, A.G., 2020. Sar-enhanced mapping of live fuel moisture content. *Remote Sensing of Environment* 245, 111797. doi :<https://doi.org/10.1016/j.rse.2020.111797>.
- Richter, R., Hutengs, C., Wirth, C., Bannehr, L., Vohland, M., 2021. Detecting tree species effects on forest canopy temperatures with thermal remote sensing : The role of spatial resolution. *Remote Sensing* 13. doi :[10.3390/rs13010135](https://doi.org/10.3390/rs13010135).
- Rogan, J., Franklin, J., 2001. Mapping wildfire burn severity in southern california forests and shrublands using enhanced thematic mapper imagery. *Geocarto International* 16, 89–99. doi :[10.1080/10106040108542218](https://doi.org/10.1080/10106040108542218).
- Rogan, J., Yool, S.R., 2001. Mapping fire-induced vegetation depletion in the peloncillo mountains, arizona and new mexico. *International Journal of Remote Sensing* 22, 3101–3121. doi :[10.1080/01431160152558279](https://doi.org/10.1080/01431160152558279).
- Rotenberg, E., Yakir, D., 2010. Contribution of semi-arid forests to the climate system. *Science* 327, 451–454. doi :[10.1126/science.1179998](https://doi.org/10.1126/science.1179998).
- Rotenberg, E., Yakir, D., 2011. Distinct patterns of changes in surface energy budget associated with forestation in the semiarid region. *Global Change Biology* 17, 1536–1548. doi :<https://doi.org/10.1111/j.1365-2486.2010.02320.x>.
- Rothermel, R.C., 1972. A mathematical model for predicting fire spread in wildland fuels. volume 115 of *USDA Forest Service research paper INT*. Intermountain Forest & Range Experiment Station, Forest Service, U.S. Department of Agriculture.
- Roy, D.P., Boschetti, L., Trigg, S.N., 2006. Remote sensing of fire severity : Assessing the performance of the normalized burn ratio. *IEEE Geoscience and Remote Sensing Letters* 3, 112–116. doi :[10.1109/LGRS.2005.858485](https://doi.org/10.1109/LGRS.2005.858485).
- Ruffault, J., Curt, T., Martin-StPaul, N.K., Moron, V., Trigo, R.M., 2018a. Extreme wildfire events are linked to global-change-type droughts in the northern mediterranean. *Natural Hazards and Earth System Sciences* 18, 847–856. doi :[10.5194/nhess-18-847-2018](https://doi.org/10.5194/nhess-18-847-2018).
- Ruffault, J., Limousin, J.M., Pimont, F., Dupuy, J.L., De Càceres, M., Cochard, H., Mouillot, F., Blackman, C.J., Torres-Ruiz, J.M., Parsons, R.A., Moreno, M., Delzon, S., Jansen, S., Olioso, A., Choat, B., Martin-StPaul, N., 2023. Plant hydraulic modelling of leaf and canopy fuel moisture content reveals increasing vulnerability of a mediterranean forest to wildfires under extreme drought. *New Phytologist* 237, 1256–1269. doi :<https://doi.org/10.1111/nph.18614>.
- Ruffault, J., Martin-StPaul, N., Pimont, F., Dupuy, J.L., 2018b. How well do meteorological drought indices predict live fuel moisture content (lfmc)? an assessment for wildfire research and operations in mediterranean ecosystems. *Agricultural and Forest Meteorology* 262, 391–401. doi :[10.1016/j.agrformet.2018.07.031](https://doi.org/10.1016/j.agrformet.2018.07.031).

- Ruffault, J., Mouillot, F., 2015. How a new fire-suppression policy can abruptly reshape the fire-weather relationship. *Ecosphere* 6, art199. doi :10.1890/ES15-00182.1.
- Ruthrof, K.X., Fontaine, J.B., Matusick, G., Breshears, D.D., Law, D.J., Powell, S., Hardy, G., 2016. How drought-induced forest die-off alters microclimate and increases fuel loadings and fire potentials. *International Journal of Wildland Fire* 25, 819–830. doi :10.1071/WF15028.
- Schlobohm, P., Brain, J., 2002. Gaining an Understanding of the National Fire Danger Rating System. PMS 932, NFES 2665, National Wildfire Coordinating Group, Fire Danger Working Team.
- Schwartz, M., Ciais, P., Ottlé, C., De Truchis, A., Vega, C., Fayad, I., Brandt, M., Fensholt, R., Baghdadi, N., Morneau, F., Morin, D., Guyon, D., Dayau, S., Wigneron, J.P., 2024. High-resolution canopy height map in the landes forest (france) based on gedi, sentinel-1, and sentinel-2 data with a deep learning approach. *International Journal of Applied Earth Observation and Geoinformation* 128, 103711. doi :<https://doi.org/10.1016/j.jag.2024.103711>.
- Sebbar, B., 2024. Combinaison de la télédétection optique/thermique et la modélisation de surface pour le suivi de l'évapotranspiration en zone montagneuse. Theses. Université Paul Sabatier - Toulouse III.
- Sebbar, B., Khabba, S., Merlin, O., Simonneaux, V., Hachimi, C.E., Kharrou, M.H., Chehbouni, A., 2023. Machine-learning-based downscaling of hourly era5-land air temperature over mountainous regions. *Atmosphere* 14. doi :10.3390/atmos14040610.
- Sebbar, B., Malbêteau, Y., Khabba, S., Bouchet, M., Simonneaux, V., Chehbouni, A., Merlin, O., 2024. Estimating evapotranspiration in mountainous water-limited regions from thermal infrared data : Comparison of two approaches based on energy balance and evaporative fraction. *Remote Sensing of Environment* 315, 114481. doi :<https://doi.org/10.1016/j.rse.2024.114481>.
- Shakesby, R.A., Chafer, C., Doerr, S.H., Blake, W.H., Wallbrink, P., Humphreys, G., Harrington, B.A., 2003. Fire severity, water repellency characteristics and hydrogeomorphological changes following the christmas 2001 sydney forest fires. *Australian Geographer* 34, 147–175. doi :10.1080/00049180301736.
- Sharples, J., Reddy, P., Resco de Dios, V., Nolan, R., Boer, M., Bradstock, R., 2024. Evaluation and comparison of simple empirical models for dead fuel moisture content. *International Journal of Wildland Fire* 33, WF23120. doi :10.1071/WF23120.
- Shaw, R.H., Pereira, A., 1982. Aerodynamic roughness of a plant canopy : A numerical experiment. *Agricultural Meteorology* 26, 51–65. doi :[https://doi.org/10.1016/0002-1571\(82\)90057-7](https://doi.org/10.1016/0002-1571(82)90057-7).
- Smith, A., Lentile, L., Hudak, A., Morgan, P., 2007. Evaluation of linear spectral unmixing and difference nbr for predicting post-fire recovery in a north american ponderosa pine forest. *International Journal of Remote Sensing* 28, 5159–5166. doi :10.1080/01431160701395161.
- Soverel, N.O., Perrakis, D.D., Coops, N.C., 2010. Estimating burn severity from landsat dnbr and rdnbr indices across western canada. *Remote Sensing of Environment* 114, 1896–1909. doi :10.1016/j.rse.2010.03.013.
- Stefan, V.G., Merlin, O., Er-Raki, S., Escorihuela, M.J., Khabba, S., 2015. Consistency between in situ, model-derived and high-resolution-image-based soil temperature endmembers : Towards a robust data-based model for multi-resolution monitoring of crop evapotranspiration. *Remote Sensing* 7, 10444–10479. doi :10.3390/rs70810444.

- Stephens, S.L., Moghaddas, J.J., Edminster, C., Fiedler, C.E., Haase, S., Harrington, M., Keeley, J.E., Knapp, E.E., McIver, J.D., Metlen, K., Skinner, C.N., Youngblood, A., 2009. Fire treatment effects on vegetation structure, fuels, and potential fire severity in western u.s. forests. *Ecological Applications* 19, 305–320. doi :<https://doi.org/10.1890/07-1755.1>.
- Still, C.J., Rastogi, B., Page, G.F.M., Griffith, D.M., Sibley, A., Schulze, M., Hawkins, L., Pau, S., Detto, M., Helliker, B.R., 2021. Imaging canopy temperature : shedding (thermal) light on ecosystem processes. *New Phytologist* 230, 1746–1753. doi :<https://doi.org/10.1111/nph.17321>.
- Stisen, S., Sandholt, I., Nørgaard, A., Fensholt, R., Jensen, K.H., 2008. Combining the triangle method with thermal inertia to estimate regional evapotranspiration — applied to msg-seviri data in the senegal river basin. *Remote Sensing of Environment* 112, 1242–1255. doi :<https://doi.org/10.1016/j.rse.2007.08.013>.
- Su, Z., 2002. The surface energy balance system (sebs) for estimation of turbulent heat fluxes. *Hydrology and Earth System Sciences* 6, 85–100. doi :[10.5194/hess-6-85-2002](https://doi.org/10.5194/hess-6-85-2002).
- Sun, H., Wang, Y., Liu, W., Yuan, S., Nie, R., 2017. Comparison of three theoretical methods for determining dry and wet edges of the 1st/fvc space : Revisit of method physics. *Remote Sensing* 9. doi :[10.3390/rs9060528](https://doi.org/10.3390/rs9060528).
- Tang, R., Li, Z.L., Tang, B., 2010. An application of the ts–vi triangle method with enhanced edges determination for evapotranspiration estimation from modis data in arid and semi-arid regions : Implementation and validation. *Remote Sensing of Environment* 114, 540–551. doi :<https://doi.org/10.1016/j.rse.2009.10.012>.
- Taylor, A.H., Harris, L.B., Drury, S.A., 2021. Drivers of fire severity shift as landscapes transition to an active fire regime, klamath mountains, usa. *Ecosphere* 12, e03734. doi :[10.1002/ecs2.3734](https://doi.org/10.1002/ecs2.3734).
- Tian, X., Li, Z., van der Tol, C., Su, Z., Li, X., He, Q., Bao, Y., Chen, E., Li, L., 2011. Estimating zero-plane displacement height and aerodynamic roughness length using synthesis of lidar and spot-5 data. *Remote Sensing of Environment* 115, 2330–2341. doi :<https://doi.org/10.1016/j.rse.2011.04.033>.
- Tompkins, S., Mustard, J.F., Pieters, C.M., Forsyth, D.W., 1997. Optimization of endmembers for spectral mixture analysis. *Remote Sensing of Environment* 59, 472–489. doi :[https://doi.org/10.1016/S0034-4257\(96\)00122-8](https://doi.org/10.1016/S0034-4257(96)00122-8).
- Touma, D., Stevenson, S., Swain, D.L., Singh, D., Kalashnikov, D.A., Huang, X., 2022. Climate change increases risk of extreme rainfall following wildfire in the western united states. *Science Advances* 8, eabm0320. doi :[10.1126/sciadv.abm0320](https://doi.org/10.1126/sciadv.abm0320).
- Trebs, I., Mallick, K., Bhattarai, N., Sulis, M., Cleverly, J., Woodgate, W., Silberstein, R., Hinko-Najera, N., Beringer, J., Meyer, W.S., Su, Z., Boulet, G., 2021. The role of aerodynamic resistance in thermal remote sensing-based evapotranspiration models. *Remote Sensing of Environment* 264, 112602. doi :<https://doi.org/10.1016/j.rse.2021.112602>.
- US Forest Service, 2003. Influence of forest structure on wildfire behavior and the severity of its effects : an overview. p. 12.
- Van Der Kwast, J., Timmermans, W., Gieske, A., Su, Z., Olivoso, A., Jia, L., Elbers, J., Karsenberg, D., de Jong, S., 2009. Evaluation of the surface energy balance system (sebs) applied to aster imagery with

- flux-measurements at the sparcs 2004 site (barrax, spain). *Hydrology and Earth System Sciences* 13, 1337–1347. doi :10.5194/hess-13-1337-2009.
- Van Wagner, C., et al., 1987. Development and structure of the Canadian forest fire weather index system. volume 35.
- Vega-Nieva, D.J., Briseño-Reyes, J., López-Serrano, P.M., Corral-Rivas, J.J., Pompa-García, M., Cruz-López, M.I., Cuahutle, M., Ressler, R., Alvarado-Celestino, E., Burgan, R.E., 2024. Autoregressive forecasting of the number of forest fires using an accumulated modis-based fuel dryness index. *Forests* 15. doi :10.3390/f15010042.
- Venturini, V., Bisht, G., Islam, S., Jiang, L., 2004. Comparison of evaporative fractions estimated from avhrr and modis sensors over south florida. *Remote Sensing of Environment* 93, 77–86. doi :https://doi.org/10.1016/j.rse.2004.06.020.
- Veraverbeke, S., Rogers, B.M., Randerson, J.T., 2015. Daily burned area and carbon emissions from boreal fires in alaska. *Biogeosciences* 12, 3579–3601. doi :10.5194/bg-12-3579-2015.
- Viedma, O., Chico, F., Fernández, J., Madrigal, C., Safford, H., Moreno, J., 2020. Disentangling the role of prefire vegetation vs. burning conditions on fire severity in a large forest fire in se spain. *Remote Sensing of Environment* 247, 111891. doi :10.1016/j.rse.2020.111891.
- Viedma, O., Quesada, J., Torres, I., Santis, A., Moreno, J., 2014. Fire severity in a large fire in a pinus pinaster forest is highly predictable from burning conditions, stand structure, and topography. *Ecosystems* 18, 237–250. doi :10.1007/s10021-014-9824-y.
- Vinodkumar, V., Dharssi, I., Yebra, M., Fox-Hughes, P., 2021. Continental-scale prediction of live fuel moisture content using soil moisture information. *Agricultural and Forest Meteorology* 307, 108503. doi :https://doi.org/10.1016/j.agrformet.2021.108503.
- Wang, K., Li, Z., Cribb, M., 2006. Estimation of evaporative fraction from a combination of day and night land surface temperatures and ndvi : A new method to determine the priestley–taylor parameter. *Remote Sensing of Environment* 102, 293–305. doi :https://doi.org/10.1016/j.rse.2006.02.007.
- Webster, C., Westoby, M., Rutter, N., Jonas, T., 2018. Three-dimensional thermal characterization of forest canopies using uav photogrammetry. *Remote Sensing of Environment* 209, 835–847. doi :https://doi.org/10.1016/j.rse.2017.09.033.
- Wells, A.G., Hawbaker, T.J., Hiers, J.K., Kean, J., Loehman, R.A., Steblein, P.F., 2019. Predicting burn severity for integration with post-fire debris-flow hazard assessment : a case study from the upper colorado river basin, usa. *International Journal of Wildland Fire* 32, 1315–1331. doi :10.1071/WF22200.
- White, J.D., Ryan, K.C., Key, C.C., Running, S.W., 1996. Remote sensing of forest fire severity and vegetation recovery. *International Journal of Wildland Fire* 6.
- Xu, D., Guo, X., Li, Z., Yang, X., Yin, H., 2014. Measuring the dead component of mixed grassland with landsat imagery. *Remote Sensing of Environment* 142, 33–43. doi :https://doi.org/10.1016/j.rse.2013.11.017.
- Yebra, M., Chuvieco, E., Riaño, D., 2008. Estimation of live fuel moisture content from modis images for fire risk assessment. *Agricultural and Forest Meteorology* 148, 523–536. doi :10.1016/j.agrformet.2007.12.005.

- Yebra, M., Dennison, P.E., Chuvieco, E., Riaño, D., Zylstra, P., Hunt, E.R., Danson, F.M., Qi, Y., Jurdao, S., 2013. A global review of remote sensing of live fuel moisture content for fire danger assessment : Moving towards operational products. *Remote Sensing of Environment* 136, 455–468. doi :10.1016/j.rse.2013.05.029.
- Yebra, M., Quan, X., Riaño, D., Rozas Larraondo, P., van Dijk, A.I., Cary, G.J., 2018. A fuel moisture content and flammability monitoring methodology for continental australia based on optical remote sensing. *Remote Sensing of Environment* 212, 260–272. doi :10.1016/j.rse.2018.04.053.
- Yebra, M., Scortechini, G., Adeline, K., Aktepe, N., Almoustafa, T., Bar-Massada, A., Beget, M.E., Boer, M., Bradstock, R., Brown, T., Castro, F.X., Chen, R., Chuvieco, E., Danson, M., Degirmenci, C.n., Delgado-Dávila, R., Dennison, P., Di Bella, C., Domenech, O., Féret, J.B., Forsyth, G., Gabriel, E., Gagkas, Z., Gharbi, F., Younes Cardenas, N., 2024. Globe-lfmc 2.0, an enhanced and updated dataset for live fuel moisture content research. *Scientific Data* 11, 332. doi :10.1038/s41597-024-03159-6.
- Yin, C., He, B., Yebra, M., Quan, X., Edwards, A.C., Liu, X., Liao, Z., 2020. Improving burn severity retrieval by integrating tree canopy cover into radiative transfer model simulation. *Remote Sensing of Environment* 236, 111454. doi :<https://doi.org/10.1016/j.rse.2019.111454>.
- Zacharakis, I., Tsihrintzis, V.A., 2023. Integrated wildfire danger models and factors : A review. *Science of The Total Environment* 899, 165704. doi :<https://doi.org/10.1016/j.scitotenv.2023.165704>.
- Zhang, D., Tang, R., Zhao, W., Tang, B., Wu, H., Shao, K., Li, Z.L., 2014. Surface soil water content estimation from thermal remote sensing based on the temporal variation of land surface temperature. *Remote Sensing* 6, 3170–3187. doi :10.3390/rs6043170.
- Zhu, X., Liu, D., 2015. Improving forest aboveground biomass estimation using seasonal landsat ndvi time-series. *ISPRS Journal of Photogrammetry and Remote Sensing* 102, 222–231. doi :10.1016/j.isprsjprs.2014.08.014.
- Zwolinski, M.J., 1990. Fire effects on vegetation and succession, in : Krammes, J.S. (Ed.), *Effects of fire management of southwestern natural resources*, USDA Forest Service, Rocky Mountain Forest and Range Experiment Station, Fort Collins, CO. pp. 18–24.

Titre : Apport de la télédétection satellitaire optique/thermique haute résolution à la prédiction de la sévérité des incendies de forêt en zone méditerranéenne française

Mots clés : incendie, télédétection, combustible, sévérité, stress hydrique, infrarouge thermique

Résumé : Le changement climatique est une menace majeure pour les écosystèmes forestiers méditerranéens, en particulier du fait de l'augmentation du risque incendie. Pourtant, l'impact des incendies sur le milieu, ie la sévérité d'un incendie, reste encore peu étudié en région méditerranéenne française. Bien que les facteurs de variabilité soient bien connus (conditions météorologiques, état du combustible, topographie), les modèles de prédiction de la sévérité potentielle, principalement développés aux États-Unis, sont difficilement généralisables. L'hypothèse est que les prédicteurs utilisés actuellement sont incomplets et/ou trop incertains aux échelles spatiales considérées. Dans ce contexte de prévision de la sévérité potentielle des incendies en région méditerranéenne, cette thèse a pour objectif de 1) tester de nouveaux prédicteurs, et 2) développer de nouveaux indicateurs du stress hydrique des écosystèmes à partir des données satellitaires infrarouges thermiques à haute résolution spatiale. La première partie de la thèse s'intéresse à la prise en compte des dynamiques temporelles pré-feu de proxys de l'état du combustible dans les modèles de prédiction de la sévérité. Les séries temporelles pré-feu d'un indice de végétation issu de la télédétection (Sentinel-2, Landsat-7/8) et d'indices de sécheresse dérivés des données météorologiques sont extraites de 79 incendies estivaux (2016-2021). La prise en compte des dynamiques du combustible durant les 2 mois précédant l'incendie améliore la performance de prédiction de 32% par rapport au modèle de référence qui n'utilise que les données juste avant l'incendie. Une augmentation plus rapide que la moyenne de la sécheresse et une diminution plus rapide que la moyenne de la quantité de combustible vivant favorisent des sévérités plus élevées que la moyenne. La deuxième partie de la thèse s'intéresse à l'estimation du stress hydrique des forêts méditerranéennes à partir des données optiques/thermiques (Landsat-7/8/9) et des données LIDAR haute définition de l'IGN. La méthode contextuelle, couramment appliquée aux couverts relativement bas et de structure homogène, est adaptée de manière originale au cas des forêts. Les résultats sont évalués sur deux sites forestiers méditerranéens où des mesures par système eddy-covariance sont disponibles pendant 9 ans. La rugosité de surface (fonction de la hauteur de canopée) et les effets directionnels (ombres portées des arbres) sont identifiés comme des facteurs de variabilité de la température de surface (LST) Landsat, indépendamment du stress hydrique. Une méthode de normalisation de la LST des effets de hauteur de canopée et une correction de l'effet des ombres portées sont donc développées. Elles permettent de réduire le biais sur les estimations satellitaires et d'augmenter leur sensibilité au stress hydrique mesuré in situ de manière très significative par rapport à la méthode sans normalisation ni correction. Le stress hydrique dérivé des données thermiques pourrait être utilisé comme prédicteur de la sévérité potentielle.

Title: Contribution of high-resolution optical/thermal satellite remote sensing to the prediction of forest fire severity in the French Mediterranean area

Key words: forest fire, remote sensing, forest fuel, fire severity, hydric stress, thermal infrared

Abstract: Climate change is a major threat to Mediterranean forest ecosystems, particularly due to the increased risk of wildfires. However, the impact of fires on the environment, ie fire severity, remains poorly studied in the French Mediterranean region. Although the variability factors are well known (meteorological and fuel conditions, topography), the models predicting potential fire severity, that are mainly developed in the United States, are difficult to generalize. The assumption is that the predictors currently used are incomplete and/or too uncertain at the spatial scales considered. In this context of predicting potential fire severity in the Mediterranean region, this thesis aims to 1) test new predictors, and 2) develop new indicators of ecosystem hydric stress using high-resolution thermal infrared satellite data. The first part of the thesis focuses on the use of pre-fire temporal dynamics of fuel state proxies in fire severity prediction models. Pre-fire time series of a vegetation index derived from remote sensing (Sentinel-2, Landsat-7/8) and drought indices derived from meteorological data are extracted from 79 summer fires (2016-2021). Considering fuel dynamics during the 2 months preceding the fire improves prediction performance by 32% compared to the benchmark model that only uses data measured or computed just before the fire. Faster-than-average increases in drought and faster-than-average decreases in live fuel quantity favour higher-than-average severities. The second part of the thesis focuses on estimating hydric stress in Mediterranean forests using optical/thermal data (Landsat-7/8/9) and high-definition LIDAR data from IGN. The contextual method, commonly applied to relatively low and homogeneous land covers, is originally adapted to the case of forests. The results are evaluated on two Mediterranean forest sites where eddy-covariance system measurements are available for 9 years. Surface roughness (function of canopy height) and directional effects (tree casting shadows) are identified as variability factors of Landsat surface temperature (LST), independently of hydric stress. A method for normalizing LST for canopy height effects and correcting for cast shadows is developed. This method reduces bias in satellite estimates and significantly increases their sensitivity to in situ measured hydric stress compared to the method without normalization and correction. Hydric stress derived from thermal data could be used as a predictor of potential fire severity.