



# Etude de la dynamique spatio-temporelle de l'humidité du sol: Applications du satellite SMOS au suivi de rendement agricole en Afrique de l'Ouest et à la correction des produits satellitaires de pluies

François Gibon

## ► To cite this version:

François Gibon. Etude de la dynamique spatio-temporelle de l'humidité du sol: Applications du satellite SMOS au suivi de rendement agricole en Afrique de l'Ouest et à la correction des produits satellitaires de pluies. Sciences de la Terre. Université Grenoble Alpes, 2018. Français. NNT : 2018GREAU013 . tel-01863752

HAL Id: tel-01863752

<https://theses.hal.science/tel-01863752>

Submitted on 29 Aug 2018

**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.

## THÈSE

Pour obtenir le grade de

### DOCTEUR DE LA COMMUNAUTÉ UNIVERSITÉ GRENOBLE ALPES

Spécialité : Océan Atmosphère et Hydrologie

Arrêté ministériel : 7 Août 2006

Présentée par

**François GIBON**

Thèse dirigée par **Thierry PELLARIN**

préparée au sein **Institut des Géosciences de l'Environnement (IGE)**  
et de **L'École doctorale Terre - Univers - Environnement**

### Étude de la dynamique spatio-temporelle de l'humidité du sol

Applications du satellite SMOS au suivi de rendement  
agricole en Afrique de l'Ouest et à la correction des  
produits satellitaires de précipitations.

Thèse soutenue publiquement le ,  
devant le jury composé de :

**Agnès BÉGUÉ**

Directrice de Recherche, CIRAD, Rapporteur

**Thierry LEBEL**

Directeur de Recherche, IRD, Président du Jury

**Olivier MERLIN**

Chargé de Recherche, CNRS, Rapporteur

**Catherine OTTÉ**

Directrice de Recherche, CNRS, Examinateuse

**Thierry PELLARIN**

Chargé de Recherche, CNRS, Directeur de thèse

**Benjamin SULTAN**

Directeur de Recherche, IRD, Examinateur





*"Essentially, all models are wrong, but some are useful"*  
George E. P. Box, Empirical Model-Building and Response Surfaces, 1987



## Résumé

L'humidité du sol a été déclarée Essential Climate Variable (ECV) en 2010 par l'European Space Agency (ESA) en support du travail du Groupe d'experts Intergouvernemental sur l'Évolution du Climat (GIEC). Dans des zones vulnérables comme l'Afrique de l'Ouest (agriculture faiblement irriguée et de subsistance, températures extrêmes et forte variabilité des précipitations), la valeur ajoutée d'informations concernant l'humidité du sol est importante, surtout dans un contexte de changement climatique. La première partie de ces travaux de thèse concerne la représentation de l'humidité en profondeur à grande échelle en utilisant le triptyque mesures in-situ/télédétection/modélisation. Ces 3 méthodes présentent chacune des limites : (i) la faible densité des réseaux in-situ (3 sites de mesures sur toute l'Afrique de l'Ouest), (ii) les estimations de SMOS uniquement en surface (0-5 cm) et (iii) les incertitudes des forçages de précipitation temps-réel utilisés dans les modèles de surface. Afin de réduire ces limitations, une méthode d'assimilation (filtre particulaire) des données SMOS a été implémentée dans un modèle de surface empirique (API) et comparées aux mesures in-situ AMMA-CATCH. Les résultats montrent une amélioration des humidités modélisée après assimilation. La seconde partie concerne l'impact des variations d'humidité du sol sur les rendements de mil. Une relation statistique a tout d'abord été déterminée à partir de données de rendements mesurés sur 10 villages autour de Niamey. Les résultats montrent que les anomalies d'humidité du sol sur 20 jours début Juillet et fin Août - mi Septembre (période reproductive et période de remplissage du grain), à une profondeur d'environ 30 cm, expliquent les variations de rendement mesuré à  $R^2=0.77$  sur l'ensemble de 9 villages. Cette relation a ensuite été appliquée à l'échelle du Niger à partir de données de rendement issues de la FAO et de cartes d'humidité en profondeur développées dans la première partie de la thèse. Les résultats montrent une corrélation à  $R^2=0.62$  sur les années 1998-2014. Puis la méthode a été appliquée à 3 autres pays du Sahel, montrant une corrélation de 0.77. La dernière partie de ces travaux concerne l'exploitation des résidus du schéma d'assimilation afin de réduire les incertitudes sur les précipitations. Les produits de précipitations satellites CMORPH, TRMM et PERSIANN, dans leur version temps-réel ont été comparées à des pluviomètres avant et après assimilation. Le résultat de cette étude montre une nette amélioration des intensités estimées. La méthode a ensuite été appliquée à un produit de précipitation utilisé au centre régional AGRHYMET pour le suivi agricole, le produit TAMSAT.

Ces travaux de thèse ont permis d'approfondir les recherches concernant le potentiel des données d'humidité par satellite pour des applications agronomiques. Les perspectives de ces travaux portent principalement sur : (i) l'utilisation d'autres capteurs (SMAP, ASCAT, AMSR) pour augmenter la fréquence des observations d'humidité dans l'assimilation, (ii) sur des méthodes de désagrégation des coefficients pour la correction des précipitations à plus haute résolution spatiale et (iii) sur l'utilisation de données multispectrales (indices de végétation, température du sol, ...) pour un meilleur suivi des rendements.

**Mots-clés :** Humidité du sol, précipitation, SMOS, assimilation, agronomie, Afrique de l'Ouest, FAO

## Abstract

Soil moisture was declared Essential Climate Variable (ECV) in 2010 by the European Space Agency (ESA) in support of the work of the Intergovernmental Panel on Climate Change (IPCC). In vulnerable areas such as West Africa (poorly irrigated and subsistence agriculture, extreme temperatures and high variability of rainfall), the added value of informations on soil moisture is important, especially in a changing climate. The first part of this thesis concerns the representation of root-zone soil moisture on a large scale using the triptych in-situ measurements / remote sensing / modeling. These 3 methods each have limitations : (i) the low density of in-situ networks (3 measurement sites throughout West Africa), (ii) SMOS estimates only at the surface (0-5 cm) and (iii) the uncertainties of the real-time precipitation forcing used in surface models. In order to reduce these limitations, an assimilation method (particle filter) of SMOS data has been implemented in an empirical surface model (API) and compared to AMMA-CATCH in-situ measurements. The results show an improvement of the humidities modeled after assimilation. The second part concerns the impact of soil moisture variations on millet yields. A statistical relationship was first determined from yield data measured in 10 villages around Niamey. The results show that the 20-day soil moisture anomalies at the beginning of July and the end of August - mid September (reproductive period and grain filling period), at a depth of about 30 cm, explain the variations in yield measured at  $R^2=0.77$ . This relationship was then applied to the Nigerien scale from FAO yield data and in-depth moisture maps developed in the first part of the thesis. The results show a correlation at  $R^2=0.62$  over the years 1998-2015. Then, the method was apply to 3 other sahelian countries, showing a agreement of 0.77. The last part of this work concerns the exploitation of the residuals of the assimilation scheme in order to reduce the uncertainties on the precipitations. The satellite precipitation products CMORPH, TRMM and PERSIANN, in their real-time version, were compared to rain gauges before and after assimilation. The result of this study shows a marked improvement in the estimated precipitations intensities. The method was then applied to a precipitation product used at the AGRHYMET regional center for agricultural monitoring, the TAMSAT product.

This thesis work has led to further research into the potential of satellite moisture data for agronomic applications. The perspectives of this work mainly concern : (i) the use of other sensors (SMAP, ASCAT, AMSR) to increase the frequency of the observations of humidity in the assimilation, (ii) on methods of disaggregation of the coefficients for the correction of precipitation at higher spatial resolution and (iii) the use of multispectral data (vegetation indices, soil temperature, ...) for a better monitoring of yields.

**Keywords :** Soil moisture, precipitation, SMOS, assimilation, agronomy, West Africa, FAO

## Remerciements

Tout d'abord, je tiens à remercier Thierry pour m'avoir guidé à travers le monde de la recherche. Je voulais particulièrement te remercier pour ta confiance, ton ouverture, ta disponibilité et ta grande patience. Cela n'a pas été un long fleuve tranquille, mais tu m'as permis de garder le cap dans les méandres de la thèse.

Merci à l'ensemble des membres du Jury d'avoir pris le temps d'évaluer mes travaux.

Merci à l'Université Joseph Fourier (UJF), devenue Université Grenoble Alpes (UGA), et le Centre National d'Études Spatiales (CNES) d'avoir financé ces travaux. Merci au Laboratoire d'études des Transferts en Hydrologie et Environnement (LTHE), devenu Institut des Géosciences de l'Environnement (IGE), de m'avoir accueilli. Merci particulièrement à l'équipe PHYREV de m'avoir donné un environnement de travail motivant aussi bien scientifiquement qu'humainement.

Je tenais aussi à remercier toute l'équipe du CESBIO à Toulouse, particulièrement Yann Kerr et Arnaud Mialon. C'est avec mon expérience au sein de l'équipe SMOS qu'est née ma motivation pour la télédétection. Vous m'avez donné goût à la recherche et au travail d'équipe.

Merci au CIRAD pour leurs précieuses expertises concernant les problématiques agricoles en Afrique de l'Ouest, particulièrement Christian Baron et Danny LoSeen. Merci aussi à l'équipe AMMA-CATCH pour leur grande motivation et dynamique.

Je tenais à remercier mes cobureaux de nous avoir supporté (moi et mon bureau) pendant ces 3 ans, merci Carlos, Catherine, Tania, Alban, et Sebastian, mon quotidien était super à vos côtés !

Merci à tous, les copains/copines du labo, d'avoir arrondi les angles de la thèse : Abdoulaye, Aude, Basile, Ben, Damien, Flo, Hélène, Louise, Jordy, Joseph, Pradeeban, Saïf, ...

Ces 3 années n'auraient pas été aussi agréables sans la présence, depuis toujours, de Tiennot et Greg, merci les gars. Merci aussi à mes amis si chers dont l'énumération aurait peu de sens de par son manque d'exhaustivité.

Je tiens aussi à remercier mes parents, mon frère et ma famille pour tout le bonheur et l'inspiration qu'ils m'apportent au jour le jour.

Et pour finir, merci à Marie pour tout.



# Table des matières

<b>Résumé/Abstract</b>	<b>1</b>
<b>Remerciements</b>	<b>1</b>
<b>Introduction</b>	<b>9</b>
0.1 Contexte général . . . . .	9
0.2 L'incertitude de l'Afrique de l'Ouest face au réchauffement climatique . . . . .	13
0.3 L'observation comme moyen d'adaptation . . . . .	15
0.4 Objectifs et plan de la thèse . . . . .	17
<b>1 L'humidité du sol, variable clé</b>	<b>19</b>
1.1 Préambule . . . . .	20
1.2 Qu'est ce que l'humidité du sol ? . . . . .	20
1.3 L'humidité du sol intervient dans... . . . . .	23
1.3.1 ... le cycle de l'eau et la balance énergétique . . . . .	23
1.3.2 ... les grands cycles biogéochimiques . . . . .	26
1.4 Méthodes d'estimation de l'humidité du sol . . . . .	27
1.4.1 La mesure <i>in-situ</i> . . . . .	27
1.4.2 Les modèles de surface . . . . .	28
1.4.3 La télédétection spatiale . . . . .	29
1.5 Problématique de l'estimation de l'humidité en zone racinaire . . . . .	30
<b>2 Estimation de l'humidité du sol en Afrique de l'Ouest :</b>	
<b>Le triptyque In-situ/Télédétection/Modélisation</b>	<b>31</b>
2.1 Introduction . . . . .	32
2.2 Une "bonne estimation" de l'humidité du sol ? . . . . .	32
2.3 Mesures in-situ : l'observatoire AMMA-CATCH comme référence . . . . .	34
2.3.1 Site du Bénin . . . . .	35
2.3.2 Site du Niger . . . . .	37
2.3.3 Quelle variabilité de l'humidité du sol entre les sondes in-situ ? . . . . .	38
2.4 Télédétection spatiale : SMOS pour les mesures globales . . . . .	43
2.4.1 Comment estimer l'humidité du sol depuis l'espace ? . . . . .	43
2.4.2 Évaluation de SMOS . . . . .	47
2.4.3 Limitations . . . . .	51
2.5 Modélisation numérique : SURFEX et API pour la simulation large échelle . . . . .	56
2.5.1 Un modèle à base physique : SURFEX . . . . .	56
2.5.2 Un modèle empirique : le modèle API . . . . .	59
2.5.3 Comparaison SURFEX/API . . . . .	60
2.5.4 Impact des incertitudes des précipitations sur les simulations d'humidité	65
2.6 Résumé et conclusion . . . . .	72

<b>3 Amélioration des estimations d'humidité du sol à travers l'assimilation de données</b>	<b>73</b>
3.1 Introduction . . . . .	74
3.2 Choix des méthodes d'assimilation . . . . .	74
3.3 Normalisation des données à travers le CDF-Matching . . . . .	78
3.4 Assimilation de SMOS en contraignant l'humidité avec un Simplified Extended Kalman Filter . . . . .	80
3.4.1 Principe du SEKF . . . . .	80
3.4.2 Résultats et discussion . . . . .	82
3.5 Assimilation de SMOS en contraignant les précipitations avec un filtre particulaire . . . . .	85
3.5.1 Principe du filtre particulaire . . . . .	85
3.5.2 Évaluation sur les sites du Bénin et du Niger . . . . .	88
3.5.3 Spatialisation de la méthode . . . . .	91
3.6 Résumé et conclusion . . . . .	94
<b>4 Suivi des rendements agricoles en Afrique de l'Ouest à partir de données d'humidité du sol</b>	<b>95</b>
4.1 Introduction . . . . .	96
4.2 Zone d'étude . . . . .	97
4.3 Méthode . . . . .	98
4.4 Étude à l'échelle locale . . . . .	99
4.4.1 Données de rendements . . . . .	99
4.4.2 Données d'humidité du sol . . . . .	100
4.4.3 Relation à l'échelle locale . . . . .	101
4.5 Étude à l'échelle nationale . . . . .	105
4.5.1 Données de rendements . . . . .	105
4.5.2 Données d'humidité du sol . . . . .	105
4.5.3 Analyse de la variabilité temporelle . . . . .	106
4.5.4 Analyse de la variabilité spatiale . . . . .	108
4.6 Étude à l'échelle régionale . . . . .	110
4.6.1 Relation à l'échelle de la bande sahélienne . . . . .	110
4.6.2 Vers des cartes de rendement ? . . . . .	113
4.7 Résumé et conclusion . . . . .	115
<b>5 Correction des produits de pluies satellite par assimilation de SMOS dans un modèle de surface</b>	<b>117</b>
5.1 Introduction . . . . .	118
5.2 Correction des précipitations via l'assimilation de SMOS . . . . .	120
5.2.1 Description de la méthode . . . . .	120
5.2.2 Évaluation sur les sites du Niger et du Bénin . . . . .	122
5.2.3 Quel est le potentiel de correction maximal de la méthode ? . . . . .	125
5.3 Vers un produit haute résolution spatiale avec le produit TAMSAT . . . . .	127
5.3.1 Le produit de précipitation TAMSAT . . . . .	127
5.3.2 Détail de la chaîne de traitement . . . . .	128
5.3.3 Résultats et discussion . . . . .	131
5.4 Résumé et conclusion . . . . .	137
<b>Conclusion Générale</b>	<b>139</b>
<b>Perspectives</b>	<b>143</b>

<b>Bibliographie</b>	<b>147</b>
<b>Annexe A Théorie de la modélisation de l'émission naturelle dans les micro-ondes</b>	<b>157</b>
A.1 Généralité sur l'onde électromagnétique . . . . .	157
A.2 Interaction onde-matière . . . . .	160
A.3 Émissivité et température de brillance . . . . .	161
<b>Annexe B De la mesure de rayonnement à l'humidité du sol, description de l'inversion d'humidité</b>	<b>163</b>
B.1 le L-MEB . . . . .	163
B.2 L'inversion d'humidité . . . . .	165
<b>Annexe C Listing SURFEX</b>	<b>167</b>
<b>Annexe D Les forçages atmosphériques</b>	<b>171</b>
<b>Annexe E Analyse à l'échelle des districts administratifs</b>	<b>177</b>
<b>Annexe F Valorisations scientifiques</b>	<b>179</b>
F.1 Publications . . . . .	179
F.1.1 Pellarin et al. 2015 : Three years of L-band brightness temperature measurements in a mountainous area : Topography, vegetation and snowmelt .	179
F.1.2 Leroux et al. 2016 : Assimilation of SMOS soil moisture into a distributed hydrological model and impacts on the water cycle variables over the Ouémé catchment in Benin . . . . .	195
F.1.3 Román-Cascón et al. 2017 : Correcting satellite-based precipitation products through SMOS soil moisture data assimilation in two land-surface models of different complexity : API and SURFEX . . . . .	210
F.1.4 Gibon et al. 2017 : Crop yield monitoring in the Sahel using SMOS satellite derived soil moisture time series . . . . .	227
F.2 Conférences/Workshop . . . . .	229
F.2.1 Gibon et al. 2015, <i>SMOS Assimilation into SURFEX Land Surface Model : Application to Crop Yield Estimate in West Africa</i> , ESA 2nd SMOS Science, El Escorial (Espagne), poster . . . . .	229
F.2.2 Gibon et al. 2015, <i>Modélisation de l'humidité du sol en assimilant des données satellitaires (SMOS) dans un modèle de surface (SURFEX) en Afrique de l'Ouest</i> , Réunion ORE AMMA-CATCH, Sète (France), poster .	231
F.2.3 Gibon et al. 2015, <i>Assimilation du produit L3SM SMOS dans le modèle de surface SURFEX en région sahélienne</i> , Workshop Modélisation de surface, CESBIO Toulouse (France), oral . . . . .	231
F.2.4 Gibon et al. 2016, <i>SMOS Assimilation into SURFEX Land Surface Model : Application to Sahelian Crop Yield Estimation</i> , ESA Living Planet Symposium, Prague (République Tchèque), poster . . . . .	232
F.2.5 Gibon et al. 2017, <i>Crop yield Monitoring in the Sahel using root zone soil moisture anomalies derived from SMOS soil moisture data assimilation</i> , EGU General Assembly, Vienne (Autriche), oral . . . . .	234
F.2.6 Román-Cascón et al. 2017, <i>Correcting satellite-based precipitation products from SMOS soil moisture data assimilation using two models of different complexity</i> , EGU General Assembly, Vienne (Autriche), oral . . .	235



## Liste des Acronymes

**API** Antecedent Precipitation Index

**CATDS** Centre Aval de Traitement des Données SMOS

**CEDEAO** Communauté Économique Des États de l'Afrique de l'Ouest

**ESA** European Space Agency

**ECV** Essential Climate Variable

**FAO** Food and Agriculture Organization of the United Nations

**GPCC** Global Precipitation Climatology Center

**IPCC** Intergovernmental Panel on Climate Change

**ISMN** International Soil Moisture Network

**L-MEB** L-band Microwave Emission of the Biosphere

**LSM** Land Surface Model

**RFI** Radio Frequency Interference

**SMAP** Soil Moisture Active/Passive

**SMOS** Soil Moisture and Ocean Salinity

**SURFEX** SURface EXternalisée

**SVAT** Surface Vegetation Atmosphere Transfer

**TAMSAT** Tropical Application of Meteorology using SATellite and ground based observation

**TB** Température de Brillance

**TDR** Time Domain Reflectometry

**UNFCCC** United Nations Framework Convention on Climate Change



# Introduction

## 0.1 Contexte général

« *L'équilibre de la vie se déploie dans plusieurs dimensions ; fragile et complexe, il ne transgresse pas certaines bornes. Il y a certains seuils à ne pas franchir.* », écrivait Ivan Illich dans son œuvre *La Convivialité* en 1973. Depuis le début de la révolution industrielle dans les années 1750, les impacts des activités humaines sur l'environnement sont tels qu'ils ont fait entrer l'Humanité dans une nouvelle ère géologique, l'Anthropocène ([Steffen et al., 2006],[Crutzen, 2002]). Durant l'ère précédente, l'Holocène, les variations environnementales, principalement naturelles, restaient dans des proportions propices au développement de l'Humanité. Cependant, l'exploitation des énergies fossiles, couplée à une croissance multifactorielle exponentielle, sont dorénavant susceptibles d'endommager l'équilibre environnemental nécessaire à la vie. Dans [Rockström et al., 2009], les auteurs font un état des lieux de certaines limites du système Terre dont les dépassemens sont dangereux pour le maintien d'un équilibre propice au développement de la vie. Or, l'un de ces systèmes, le système climatique, est particulièrement impacté par l'action humaine depuis le début de l'ère industrielle, et tend à dépasser des limites critiques. En effet, la combustion massive des énergies fossiles particulièrement depuis les années 1950 a généré une augmentation extrêmement rapide de la concentration de dioxyde de carbone ( $CO_2$ ) dans l'atmosphère.

La Figure 1 représente l'évolution de la concentration atmosphérique de  $CO_2$  depuis 55 millions d'années. Des estimations indirectes par isotopie du bore (cercles bleus), par l'étude d'alcénones (triangles noirs) ou encore par l'étude des stomates de feuilles fossilisées (losanges verts) ont permis d'estimer cette concentration pour la période depuis 55 à 1 millions d'années. Puis les mesures dans des carottes de glace en Antarctique ont permis de dériver des chroniques de concentration de  $CO_2$  présent dans l'atmosphère depuis 800 000 ans (trait plein noir). Enfin depuis les années 1800 jusqu'à aujourd'hui, des mesures atmosphériques directes (en rose) permettent d'illustrer la forte rupture de variabilité depuis les années 1950.

Le  $CO_2$ , naturellement présent dans l'atmosphère est un des principaux gaz à effet de serre (avec la vapeur d'eau ( $H_2O$ ), le méthane ( $CH_4$ ), le protoxyde d'azote ( $N_2O$ ) et l'ozone ( $O_3$ )). C'est-à-dire qu'il contribue à une élévation de la température de l'atmosphère en réémettant le rayonnement infrarouge tellurique, et contribue donc à disposer d'un environnement compatible avec le développement de la vie.

La forte augmentation de concentration de  $CO_2$  illustrée en rose Figure 1 contribue donc à augmenter l'effet de serre. Cette augmentation a pour conséquence une élévation de la température à l'échelle globale. Différents organismes scientifiques se sont réunis sous le couvert de l'Intergovernmental Panel on Climate Change (IPCC) (ou GIEC en français) pour regrouper toutes les informations disponibles concernant ce réchauffement et ses conséquences. À l'aide de nombreux modèles numériques de circulation générale, certaines projections ont donc pu

être établies en fonction des différents scénarios de changement possible d'émissions de  $CO_2$ . Ainsi, les courbes après 2017 sur la Figure 1, tirée de [Meehl et al., ], représentent l'éventail de possibilités des émissions de  $CO_2$  futures selon différents scénarios prenant en compte différents futurs en termes d'évolution démographique, de politique d'atténuation ou encore de mix énergétique.

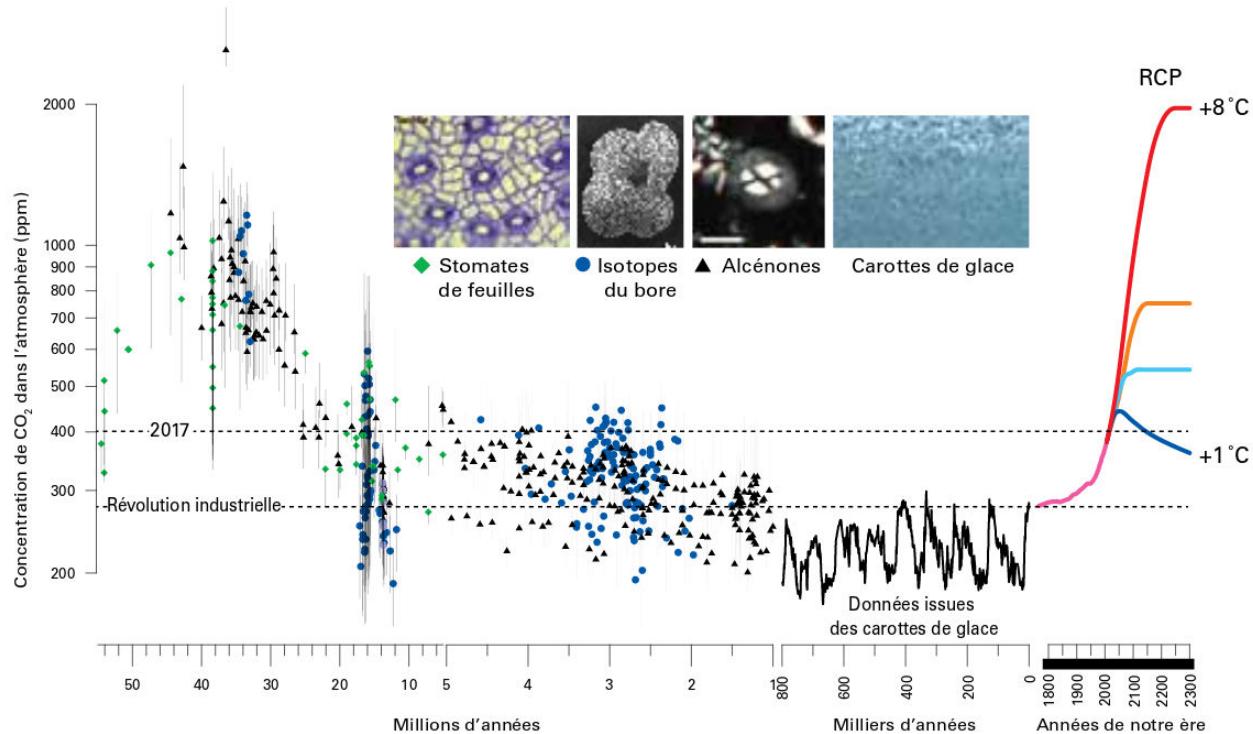


FIGURE 1 – Évolution de la concentration de  $CO_2$  atmosphérique depuis 50 millions d'années, d'après le bulletin de l'Organisation Météorologique Mondiale sur les gaz à effet de serre, 30 octobre 2017.

Le système Terre étant un système complexe, cette élévation des températures a, et aura, de nombreux effets sur les grands cycles de l'eau, du carbone et de l'énergie, et donc sur la biosphère en général. L'IPCC inventorie plusieurs effets attendus avec différents niveaux d'importance en fonction de l'élévation de température attendue, avec notamment de forts impacts sur la production alimentaire mondiale.

L'impact du réchauffement climatique sur l'agriculture à l'échelle mondiale est relativement complexe à quantifier car fortement multifactoriel. Cependant, certaines études, effectuées à partir de modélisation climatique (GCM), socio-économique ou encore agronomique, ont étudié l'effet du réchauffement climatique sur la production agricole. Dans [Rosenzweig and Parry, 1994], les auteurs estiment, à partir de différents scénarios d'émission dans des GCM couplés à des modèles agronomiques, que doubler la concentration en  $CO_2$  impacterait négativement les cultures. Cependant, toujours d'après l'étude, de faible mesures d'adaptation (simulées) permettraient de pallier cette réduction, en particulier : modification des calendriers des cultures, choix de variétés adaptées, irrigation et utilisation de fertilisants. Dans [Fischer et al., 2005], les auteurs ont intégré une composante socio-économique d'offre/demande. Il en résulte que sans adaptation, une augmentation des contrastes production/consommation entre sociétés plus ou moins résilientes est attendue. Dans [Parry et al., 2005], les auteurs s'intéressent plus particulièrement au risque de famine. En utilisant trois scénarios d'émissions sur des modèles agronomiques, ils identifient trois principales causes de l'impact du réchauffement sur les rendements : (i) une

réduction de la durée de la phase phénologique de remplissage de grain, (ii) une réduction de l'eau disponible dans certaines régions du monde et (iii) une faible vernalisation. Les principales conclusions de cette étude sont : (i) la région la plus à risque est l'Afrique, (ii) une stabilisation des concentrations à 550 ppm permettrait d'éviter la majorité des risques et (iii) l'impact du réchauffement sur les risques de famine est fortement dépendant du développement. Dans [Lobell and Field, 2007], les auteurs abordent les impacts du réchauffement sur les rendements au travers des modèles statistiques entre température, précipitation et rendement. Ils concluent que malgré la complexité des productions agricoles, 30% des variations annuelles de rendement pour les six variétés de céréales les plus cultivées dans le monde peuvent être expliquées par des variations de température et de précipitation. Dans [Müller et al., 2010], les auteurs ont analysé l'impact de cette augmentation de température sur le rendement agricole à l'aide de modèles de circulation générale et de modèles agronomiques (Figure 2). Les couleurs de la carte Figure 2 correspondent aux projections de changement de rendement pour 11 cultures différentes (blé, riz, maïs, mil, pois, betterave, pomme de terre, soja, arachide, tournesol et colza) de 2046 à 2055 en comparaison avec les années 1996–2005. Le résultat de ce changement résulte de la moyenne de trois scénarios d'émissions au travers de cinq GCM. Ces estimations sont faites avec l'hypothèse de non fertilisation de  $CO_2$  par les plantes. En effet, l'augmentation massive de  $CO_2$  peut potentiellement améliorer la croissance des plantes ainsi que leur efficacité à extraire l'eau du sol.

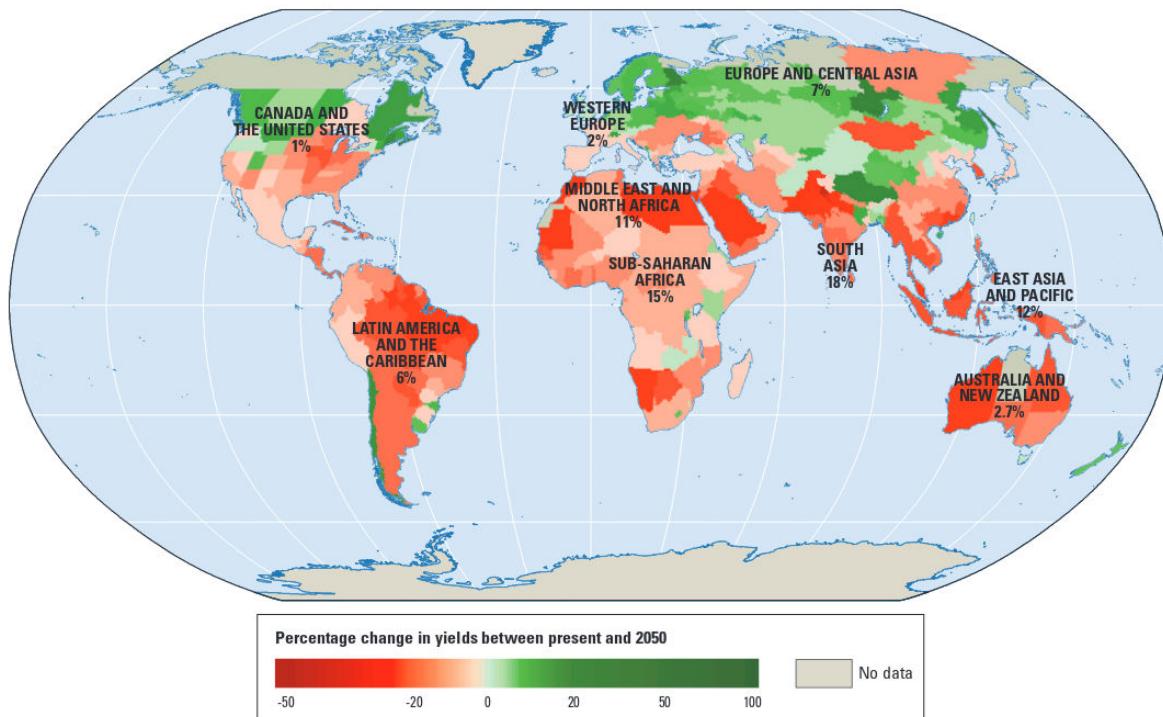


FIGURE 2 – Estimation de l'évolution des rendements agricoles en 2050 (avec la part de la contribution agricole dans le PIB de la région en %), [Müller et al., 2010].

Les pourcentages des régions correspondent à la part de PIB de la région dépendant des activités agricoles. On observe alors que la plupart des pays souffrant déjà d'une faible résilience et dont l'économie est fortement dépendante de l'activité agricole risquent de voir leur rendement agricole diminuer d'ici 2050. L'Afrique subsaharienne ne déroge pas au phénomène.

Le suivi des cultures à large échelle et l'estimation des rendements agricoles sont essentiels au développement et à la planification économique [Whitcraft et al., 2015]. Une connaissance précise du rendement des cultures contribue également à réduire les risques de comportements

## 0.1. CONTEXTE GÉNÉRAL

---

spéculatifs et limite ainsi la volatilité des prix alimentaires [Hoffman et al., 2015]. En raison du réchauffement climatique, la plupart des pays en développement devront faire face à des risques accrus liés aux événements climatiques extrêmes, comme les sécheresses, les inondations et les vagues de chaleur (IPCC 2012, 2014), de sorte que les préoccupations actuelles concernant la variabilité observée du rendement des cultures devraient encore s'accroître. La menace du changement climatique sur la sécurité alimentaire mondiale engendre l'un des défis les plus importants du XXI<sup>ème</sup> siècle, À savoir fournir une nourriture suffisante à la population toujours plus nombreuse dans un environnement déjà stressé.

La problématique du rendement est également très importante d'un point de vue de l'occupation des sols. En effet, la surface agricole augmente continuellement, notamment à cause de la forte consommation de viande des pays fortement industrialisés. Or, la production d'1 kg de viande nécessite en moyenne 15 000 L d'eau, 323 m<sup>2</sup> de terrain (source WWF) et 15 kg de céréales (source PNUE). Ces surfaces sont telles que l'expansion des zones agricoles empiète sur les forêts, engendrant donc une déforestation massive (qui est un amplificateur du réchauffement climatique).

## 0.2 L'incertitude de l'Afrique de l'Ouest face au réchauffement climatique

L'Afrique de l'Ouest est la région occidentale de l'Afrique subsaharienne. Regroupée aujourd'hui sous la Communauté Économique Des États de l'Afrique de l'Ouest (CEDEAO), cette région contient les pays du Bénin, Burkina Faso, Cap-Vert, Côte d'Ivoire, Gambie, Ghana, Guinée, Guinée-Bissau, Libéria, Mali, Niger, Nigéria, Sénégal, Sierra Leone et Togo. Avec plus de 320 millions d'habitants et 6 140 000 km<sup>2</sup>, c'est la région africaine la plus densément peuplée. Et cette densification de population va encore augmenter dans les prochaines décennies car d'après les projections du service démographique des Nations Unies (<https://esa.un.org/unpd/wpp/>), cette région de l'Afrique devrait atteindre un milliard d'habitants d'ici 2100, soit trois fois plus qu'aujourd'hui.

L'agriculture est l'activité principale de la population (>70 pour cent [Ickowicz et al., 2012]), représentant les moyens de subsistance pour des millions de personnes qui en dépendent pour les céréales, la viande, le lait, le fumier et comme un réservoir de richesse [Ly et al., 2010]. En termes de superficie cultivée, les dix principales cultures sont : le mil, le sorgho, le niébé, le maïs, l'arachide, le cacao, le manioc, le riz, l'igname et le palmier à huile. Cette agriculture est majoritairement pluviale, avec moins de 1% d'irrigation sur une surface de 10 millions d'ha cultivés [Gadelle, 2001]. Or cette région est soumise à une très forte saisonnalité des précipitations, avec la mousson, comme le montre la Figure 3. Sur la Figure 3, on remarque la très forte saisonnalité des précipitations due à la mousson africaine. Cela a pour conséquence de répartir l'ensemble des précipitations sur 3–4 mois seulement. Si l'on ajoute les très fortes températures présentes dans cette région, la saison des pluies est donc critique pour l'agriculture.

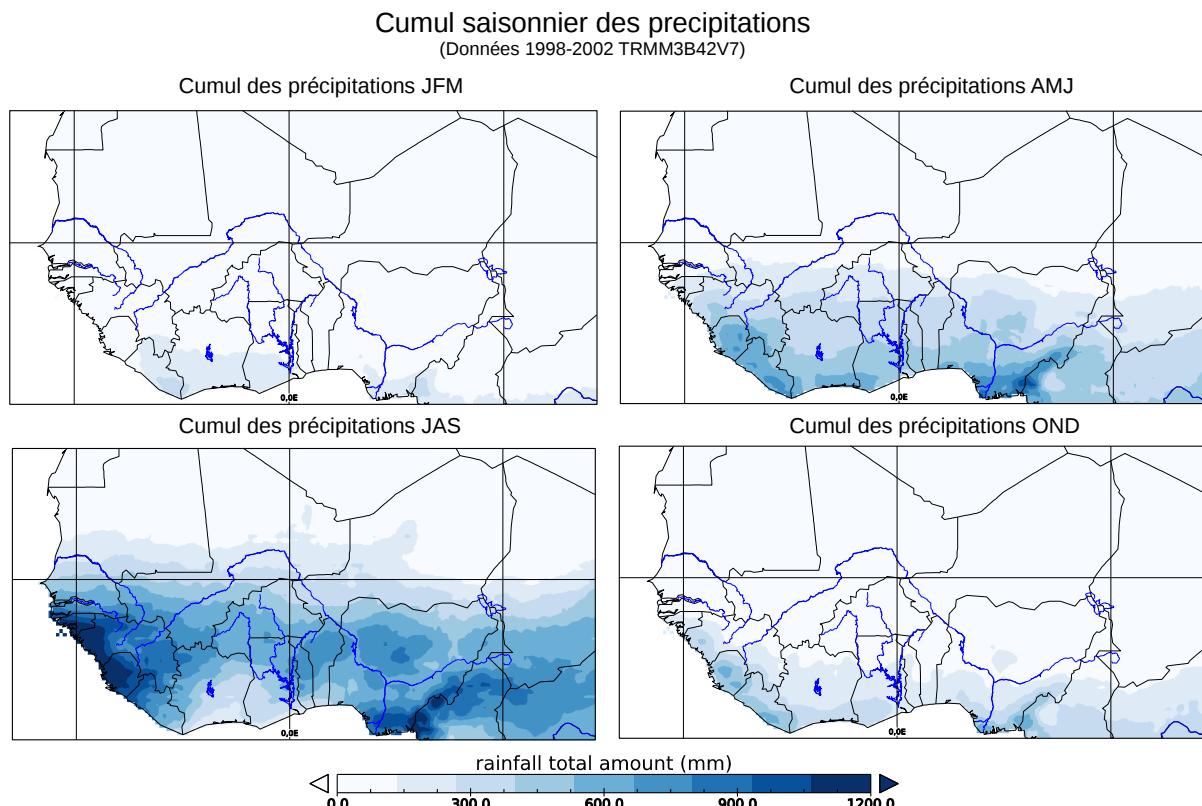


FIGURE 3 – Cumuls saisonniers des précipitations représentant les variations latitudinales de la ZCIT (données CMORPH).

## 0.2. L'INCERTITUDE DE L'AFRIQUE DE L'OUEST FACE AU RÉCHAUFFEMENT CLIMATIQUE

Cependant, l'ampleur et les conséquences du réchauffement climatique sur les températures et les précipitations restent fortement incertaines dans cette région. La Figure 4, extraite du rapport de l'IPCC 2014 [Barros et al., 2014], représente les variations de température et de précipitation en Afrique de l'Ouest. Les courbes représentent, en noir, les mesures passées et présentes et les enveloppes, les 63 simulations. On distingue ici 2 scénarios d'émissions, un premier avec augmentation significative des émissions (enveloppe rouge RCP8.5) et un autre avec réduction des émissions (enveloppe bleue RCP2.6). On remarque alors que les projections de température donnent un signal assez fort, de +1 à +5 °C en 2100. Le signal sur les précipitations paraît en revanche beaucoup plus incertain avec ± 20% en 2100. De nombreuses études autour des extrêmes de températures et des précipitations montrent, quant à elles, une tendance à l'augmentation ([Panthou et al., 2014], [Sylla et al., 2010]) générant une augmentation des événements extrêmes (vagues de chaleurs, sécheresses, inondations, ect...) dans cette région.

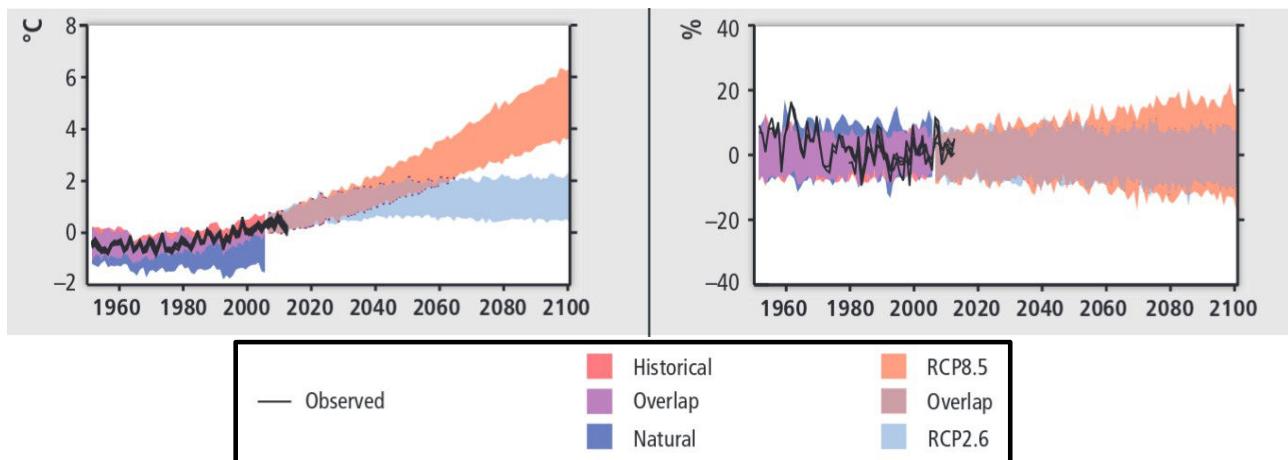


FIGURE 4 – Variations de température (à gauche) et de précipitation (à droite) en Afrique de l'Ouest, de 1950 à aujourd'hui, puis les projections de l'IPCC jusqu'en 2100 (selon 2 scénarios d'émissions) [Barros et al., 2014].

Ces fortes incertitudes se répercutent sur les impacts potentiels du réchauffement sur l'agriculture dans cette région. En effet, même si la tendance semble montrer une réduction d'environ 10% des rendements agricoles [Müller et al., 2010], dans [Roudier et al., 2011] les auteurs mitigent ce résultat. En effet, en combinant modèle climatique et modélisation agronomique sur les pays d'Afrique de l'Ouest (Niger, Mali, Burkina Faso, Sénégal, Gambie, Bénin, Togo, Nigeria, Ghana, Liberia, Sierra Leone, Cameroun, Guinée, Guinée Bissau et Côte d'Ivoire), les auteurs ont identifié cinq paramètres pour lesquels le résultat des projections d'évolution de rendement était très sensible. Dans ces paramètres, on retrouve la fertilisation de la végétation par l'augmentation du  $CO_2$ , le scénario d'émissions choisi, le choix du modèle agronomique, le type de culture et la zone d'étude. En faisant varier ces paramètres les auteurs ont montré que même si la tendance était à la baisse, la dispersion était très grande, allant de -50% à +90% d'évolution des rendements dans une cinquantaine d'années.

De nombreux processus sont impliqués dans le réchauffement et les couplages sont très nombreux. Par exemple, dans [Defrance et al., 2017], les auteurs étudient la modification du régime de mousson lors d'une fonte rapide du Groenland (événement de Heinrich) avec un scénario d'émission de  $CO_2$  en augmentation (RCP8.5). Ils ont alors observé une réduction des précipitations sur le Sahel, engendrant des modifications dans les pratiques agricoles. Ils concluent que : *We estimate that, without any adaptation measures, tens to hundreds million people could be forced to leave the Sahel by the end of this century.*

## 0.3 L'observation comme moyen d'adaptation

Pour faire face aux risques attendus par l'Afrique de l'Ouest, différentes initiatives d'adaptation sont actuellement mises en place. L'une d'elles, l'initiative pour l'Adaptation de l'Agriculture Africaine (AAA) aux changements climatiques, promeut et soutient trois types de solutions en matière de gestion des risques climatiques : (i) le développement et l'amélioration des systèmes d'observation et de prévision, (ii) le développement de l'assurance agricole et (iii) le développement des programmes de formation. C'est sur le premier point, relatif à l'amélioration des systèmes d'observation, que s'inscrit l'utilisation des produits satellitaires.

L'utilisation de la télédétection satellite comme moyen d'observation pour le suivi de la biosphère date des premiers satellites civils d'observation de la Terre dans les années 70. D'abord dans les longueurs d'onde du visible, les capteurs embarqués ont évolué et permettent maintenant de mesurer des rayonnements dans une large palette de longueurs d'onde. Ces derniers sont chargés d'alimenter les bases de données des systèmes d'alerte précoce de risques alimentaires, d'assurances indicielles, de cadastres, d'agriculture de précision et plus globalement pour le suivi des cultures cultivées.

On peut diviser en deux groupes les produits issus d'observations satellitaires pouvant répondre à la problématique du suivi de culture : les produits relatifs à l'environnement climatique et les produits plus axés sur la biophysique de la végétation. Dans le premier groupe on retrouve principalement les produits de précipitation, de rayonnement et de température. Ces derniers permettent de dériver des anomalies pouvant avoir un impact soit positif (précipitation importante couplée à un bon rayonnement, ...) ou alors négatif (sécheresse, vague de chaleur, ...). Dans le second groupe, on retrouve les produits tels que les indices d'activité photosynthétique (NDVI, EVI, fluorescence, ...) et les surfaces foliaires (LAI), l'évapotranspiration et la température de surface, la productivité et biomasse et enfin l'humidité du sol (Figure 5).

Les données les plus courantes reposent sur la télédétection optique et proche infrarouge pour dériver les indices de végétation (VIs pour Vegetation Indices) qui fournissent un indicateur global de la couverture de la photosynthèse ou de l'indice de surface foliaire ([[Sellers et al., 1992](#)], [[Guan et al., 2015](#)]). L'indice de végétation normalisé (NDVI) a été l'un des premiers VIs développés [[Tucker, 1979](#)] et a été largement utilisé pour la surveillance opérationnelle des cultures ([[Maselli et al., 1992](#)], [[Funk and Budde, 2009](#)]). Diverses méthodes pour estimer le rendement des cultures ont également été proposées en utilisant des mesures de température de surface (LST), de fluorescence et de rayonnement micro-ondes. Les mesures de température de surface peuvent également être utilisées pour estimer l'évapotranspiration, ce qui peut être étroitement lié à la disponibilité de l'eau de la plante ([[Anderson et al., 2013](#)]). La fluorescence a également été utilisée comme proxy de la photosynthèse des plantes ([[Guanter et al., 2014](#)], [[Guan et al., 2016](#)]). Enfin, les micro-ondes ont été utilisées pour dériver l'épaisseur optique de la végétation, qui est principalement liée à la teneur en eau de la végétation et à la biomasse ([[Liu et al., 2011](#)], [[Guan et al., 2014](#)]).

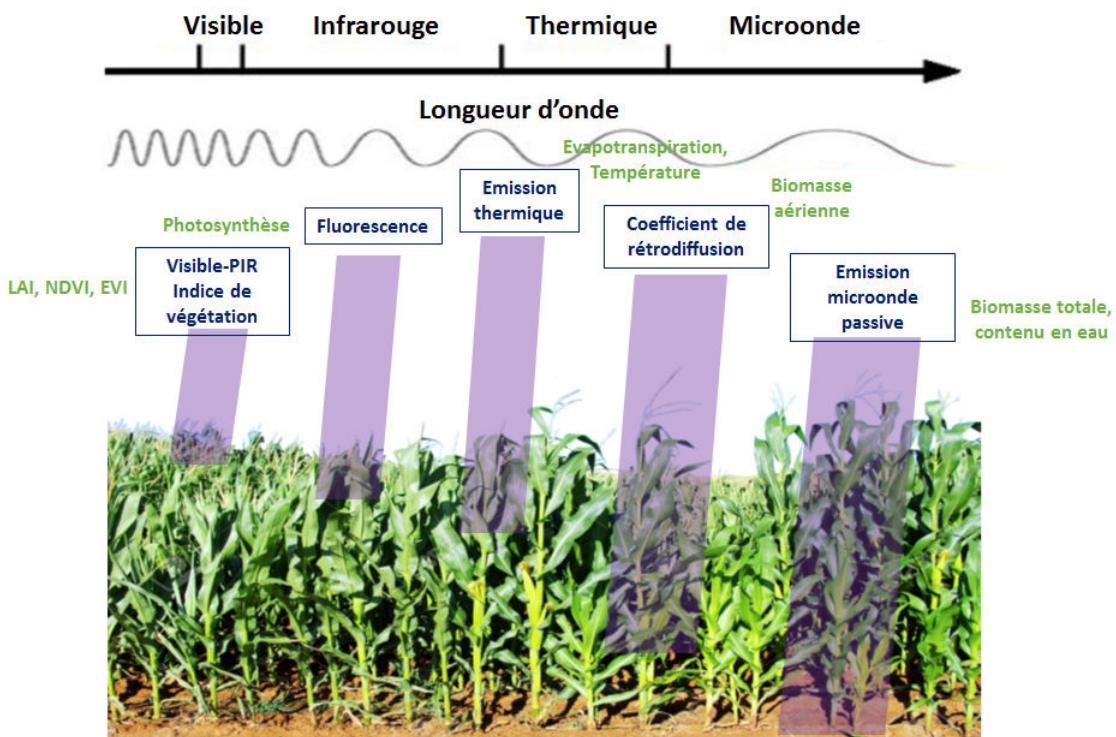


FIGURE 5 – Exemples de paramètres de la végétation mesurables par télédétection en fonction de différentes longueurs d'onde.

Bien que de nombreuses études aient montré de bonnes relations entre différents VIs et le rendement des cultures ([[Bolton and Friedl, 2013](#)], [[Mkhabela et al., 2011](#)], [[Leroux et al., 2016](#)]), la prise en compte du stress hydrique dans cette relation ([[Ines et al., 2013](#)], [[McNally et al., 2015](#)]) est resté peu exploité. Cela s'explique notamment par la large utilisation des données satellitaires dans les longueurs d'onde du visible et de l'infrarouge depuis le début des années 80 (tels que AVHRR, MODIS, VIIRS et les capteurs satellites géostationnaires). Les mesures d'humidité du sol, nécessitant la mesure de longueurs d'onde plus grandes ( $\sim 30$  cm), sous-entendent l'utilisation de grandes antennes (donc des technologies plus avancées) pour capter les faibles émissions de la terre. Pour cette raison, seuls deux satellites ont été spécifiquement développés pour surveiller l'humidité du sol : la mission de Soil Moisture and Ocean Salinity (SMOS) lancée par l'ESA fin 2009 ([[Kerr et al., 2001](#)], [[Kerr et al., 2016](#)]) et Soil Moisture Active/Passive (SMAP) lancée par la NASA au début de 2015 ([[Entekhabi et al., 2010a](#)]). Auparavant, les algorithmes d'estimation de l'humidité du sol étaient basés sur des longueurs d'onde plus courtes, tels que AMSR-E ou ASCAT mais avec une atténuation non négligeable du signal émis par le sol en raison de la couverture végétale.

## 0.4 Objectifs et plan de la thèse

Dans des zones vulnérables comme l’Afrique de l’Ouest, la valeur ajoutée d’informations concernant la représentation à large échelle de l’humidité du sol est importante. En effet, le fort rayonnement solaire couplé à la forte variabilité pluviométrique rend l’humidité du sol, facteur limitant de nombreux processus de l’interface continentale, notamment la croissance végétale. Cependant, le réseau d’observations *in-situ* ne permet pas de représentation à large échelle. L’utilisation de la télédétection et de la modélisation sont donc des solutions proposées.

Afin d’investiguer ces thématiques, cette thèse s’articule selon 3 problématiques :

### 1. Comment estimer l’humidité du sol en Afrique de l’Ouest ?

Nous verrons dans le [Chapitre 1](#), un état de l’art sur l’estimation d’humidité du sol, avec sa définition, ses interactions dans le système Terre et les méthodes classiques d’estimation, à savoir la mesure *in-situ*, la télédétection et la modélisation. Dans le [Chapitre 2](#), nous appliquerons ces méthodes spécifiquement à l’Afrique de l’Ouest. Ces méthodes ont certaines limites et incertitudes qui brident leurs utilisations. Ainsi, dans le [Chapitre 3](#), nous verrons comment coupler les données de télédétection à la modélisation afin de réduire l’incertitude et améliorer la qualité des estimations d’humidité du sol en zone racinaire à large échelle.

### 2. Quel est le potentiel des variations d’humidité du sol à expliquer les variations de rendement agricole en Afrique de l’Ouest ?

Dans le [Chapitre 4](#) une analyse est effectuée afin d’étudier le potentiel du produit d’humidité du sol à estimer les variations de rendements céréaliers en Afrique de l’Ouest. Pour cela nous étudierons tout d’abord un cas à l’échelle locale afin de caractériser le lien entre les deux variables. Dans un second temps, nous utiliserons le produit d’humidité du sol développé dans le [Chapitre 3](#) afin d’estimer le potentiel à large échelle.

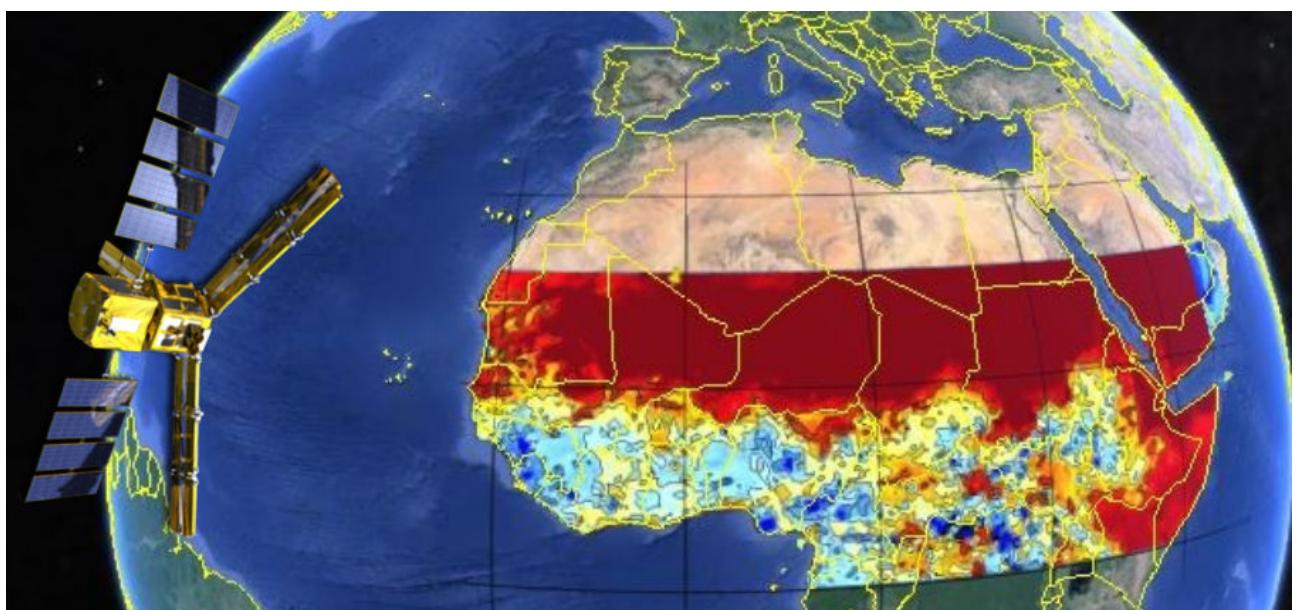
### 3. Comment améliorer l’estimation des précipitations par satellite à partir des observations d’humidité du sol SMOS ?

La problématique de l’estimation de l’humidité du sol à large échelle tient aussi à la qualité des estimations des précipitations. Or, dans la méthode développée [Chapitre 3](#) il est possible d’intégrer les informations d’humidité du sol par télédétection dans les produits de précipitations satellitaires afin de réduire leurs incertitudes, et ainsi améliorer leurs estimations. Dans le [Chapitre 5](#), nous verrons comment intégrer les données d’humidité du sol issues du satellite SMOS par assimilation puis comment les appliquer à un produit de précipitation à haute résolution spatiale, et utilisé par les agences de suivi agricole, le produit TAMSAT.

Mes travaux de recherche m'ont permis de contribuer à différentes publications dans des revues à comité de relecture :

## Publications

- **Études des effets topographiques sur la radiométrie en bande L :**  
T. Pellarin, A. Mialon, R. Biron, C. Coulaud, **F. Gibon**, Y. Kerr, M. Lafaysse, B. Mercier, S. Morin, I. Redor, M. Schwank, I. Völksch : *Three years of L-band brightness temperature measurements in a mountainous area : Topography, vegetation and snowmelt issues*, **2016**, Remote Sensing for Environment, DOI :10.1016/j.rse.2016.02.047.
- **Assimilation de SMOS dans un modèle hydrologique avec étude l'impact sur les débits :**  
D. Leroux, T. Pellarin, T. Vischel, JM. Cohard, T. Gascon, **F. Gibon**, A. Mialon, S. Galle, C. Peugeot et L. Seguis, *Assimilation of SMOS soil moisture into a distributed hydrological model and impacts on the water variable over the Ouémé catchment in Bénin*, **2016**, HESS, DOI :10.5194/hess-20-2827-2016.
- **Comparaison de l'assimilation de SMOS dans deux modèles de surface, et corrections des erreurs de pluies satellite :**  
C. Roman-Cascon, T. Pellarin, **F. Gibon**, L. Brocca, E. Cosme, W. Crow, D. Fernandes-Pietro, Y. Kerr et C. Massari, *Correcting satellite-based precipitation products through SMOS soil moisture data assimilation in two land-surface models of different complexity : API and SURFEX*, **2016**, Remote Sensing for Environment, DOI :10.1016/j.rse.2017.08.022.
- **Étude de l'impact des variations d'humidité du sol sur les rendements de mil en Afrique de l'Ouest :**  
**F. Gibon**, T. Pellarin, C. Román-Cascón, A. Alhassane, S. Traoré, Y. Kerr, D. Lo Seen, C. Baron, *Millet Yield estimations in Sahel using satellite derived soil moisture time series*, **2017**, Agricultural and Forest Meteorology (in review)



SMOS survolant le Sahel sur fond de carte SURFEX.

# Chapitre 1

## L'humidité du sol, variable clé

---

<b>1.1</b>	<b>Préambule . . . . .</b>	<b>20</b>
<b>1.2</b>	<b>Qu'est ce que l'humidité du sol ? . . . . .</b>	<b>20</b>
<b>1.3</b>	<b>L'humidité du sol intervient dans... . . . . .</b>	<b>23</b>
1.3.1	... le cycle de l'eau et la balance énergétique . . . . .	23
1.3.1.1	Rôle dans le cycle de l'eau . . . . .	23
1.3.1.2	Rôle dans la balance énergétique de surface . . . . .	24
1.3.1.3	Les rétroactions humidité du sol $\rightleftharpoons$ atmosphère . . . . .	25
1.3.2	... les grands cycles biogéochimiques . . . . .	26
<b>1.4</b>	<b>Méthodes d'estimation de l'humidité du sol . . . . .</b>	<b>27</b>
1.4.1	La mesure <i>in-situ</i> . . . . .	27
1.4.2	Les modèles de surface . . . . .	28
1.4.3	La télédétection spatiale . . . . .	29
<b>1.5</b>	<b>Problématique de l'estimation de l'humidité en zone racinaire . . . . .</b>	<b>30</b>

---

## 1.1 Préambule

L'humidité du sol a été déclarée Essential Climate Variable (ECV) en 2010 par l'European Space Agency (ESA) en support du travail de l'United Nations Framework Convention on Climate Change (UNFCCC) et de l'IPCC. C'est une des variables clés de l'interface sol/biosphère/atmosphère. Malgré sa faible proportion par rapport à la quantité totale d'eau sur Terre (seulement 0.05% de l'eau douce et 0.001% de l'eau totale [Gleick, 1993]), les impacts de ses variations sont très forts sur le cycle de l'eau, du carbone et de la balance énergétique. En effet, l'humidité du sol intervient au niveau de nombreux processus physiques tels que le développement de la végétation, le remplissage des aquifères ou encore le ruissellement de surface. La qualité des prévisions météorologiques ou encore la modélisation climatique dépendent aussi de la qualité des représentations de l'humidité du sol dans les schémas de surface. En effet, dans [Boé and Terray, 2014], les auteurs montrent que l'impact du réchauffement prévu sur l'Europe se traduit, suivant les modèles de climat par : une forte réduction des précipitations pour les modèles dont l'évapotranspiration est limitée par l'humidité du sol, ou au contraire, des précipitations inchangées pour les modèles où l'évapotranspiration n'est pas limitée par l'humidité du sol. Pouvoir étudier les variations de ce paramètre à l'échelle globale est donc primordial dans un contexte de climat changeant. Longtemps difficile à estimer à l'échelle mondiale faute de faible densité des réseaux *in-situ* nécessaires pour observer ces variations, les évolutions technologiques en matière de télédétection spatiale et de modélisation numérique permirent de grandes avancées dans l'estimation de l'humidité du sol à l'échelle de la planète.

## 1.2 Qu'est ce que l'humidité du sol ?

Avant tout, commençons par une brève définition comme la quantité d'eau contenue dans la zone non saturée du sol (aussi appelée zone de Vadose). Elle s'exprime comme le rapport entre le volume d'eau contenu dans un volume de sol (volume A ou B de Fig 1.1) où l'eau peut encore s'infiltrer ([Hillel, 1998], Equation (1.1)) :

$$\theta = \frac{\text{Volume d'eau contenu dans } V}{\text{Volume } V} \quad (1.1)$$

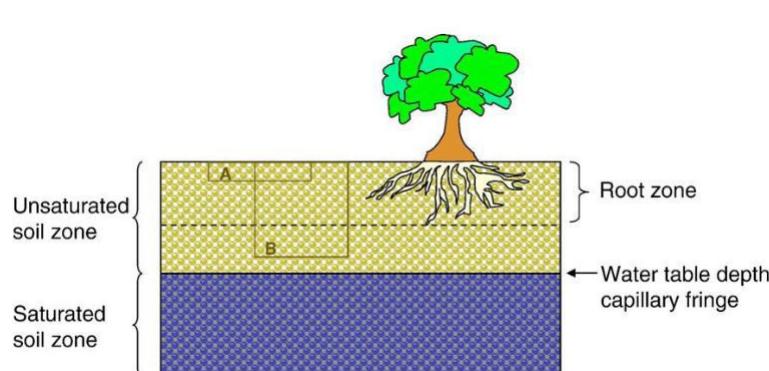


FIGURE 1.1 – L'humidité du sol est, quelque soit le volume A ou B, le rapport entre la quantité d'eau dans ce volume et ce volume (tiré de [Seneviratne et al., 2010]).

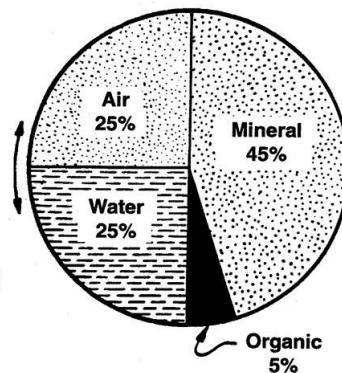


FIGURE 1.2 – A l'échelle temporelle d'un événement pluvieux, la proportion minéral/organique reste la même, la flèche représente les variations des proportions eau/air liées à l'humidité du sol (tiré de <https://passel.unl.edu/>).

Ce volume d'eau est donc intimement lié au sol. Intéressons nous donc au sol. La définition du *Larousse 2015* définit le sol comme étant : "Formation naturelle de surface, meuble, résultant de la transformation, au contact de l'atmosphère, de la roche mère sous-jacente, sous l'influence des processus physiques, chimiques et biologiques. Le sol se caractérise par un ensemble de couches, ou horizons, qui traduisent la dynamique de sa formation".

Le sol est principalement composé d'éléments minéraux et organiques, mais aussi d'eau, d'air et de gaz contenu dans ses espaces libres, les pores. Les éléments minéraux constituent la "structure du sol", la matrice, et les composés organiques, l'humus. Il existe un très grand nombre de classes de sol. La fraction minérale du sol peut être classée en 3 grandes familles de grain. Soit, du plus fin au plus grossier, l'argile ( $<2\mu\text{m}$ ), le limon ( $2\text{-}20\mu\text{m}$ ) et le sable ( $20\mu\text{m}\text{-}2\text{mm}$ ) (NF P18-560). Les proportions minérales/organiques/pores, Figure (1.2), dépendent fortement de la localisation géographique et définissent la nature du sol. Par exemple, le sol d'un désert aura une proportion minérale très grande comparée à la proportion de matière organique, cela dû à l'altération principalement mécanique engendrée par les températures extrêmes, vents, et aux faibles apports en eau et en matières organiques. Dans les sols à fort apport d'eau et de matières organiques, la dégradation chimique et biologique du sol génère de l'humus et la proportion organique/minérale est plus équilibrée. Ce sont les proportions eau/air des pores qui varient au travers de l'humidité du sol (flèche sur Figure 1.2).

Le paramètre, qui caractérise cette proportion d'espace libre pour l'eau et l'air dans une matrice de sol, est appelé la *porosité*. Elle peut être faible dans le cas des sols sableux (25 à 40%) ou élevée dans le cas des sols argileux (de 40 à 50%). La granulométrie, la structure, la compacité ou encore la teneur initiale en eau, conditionne le volume d'espace libre. La capacité de l'eau à s'infiltrer dans le sol dépend fortement de ce volume disponible. Une fois dans le sol, les particules d'eau subissent 3 forces principales : la gravité, la capillarité et la succion (Figure 1.3)

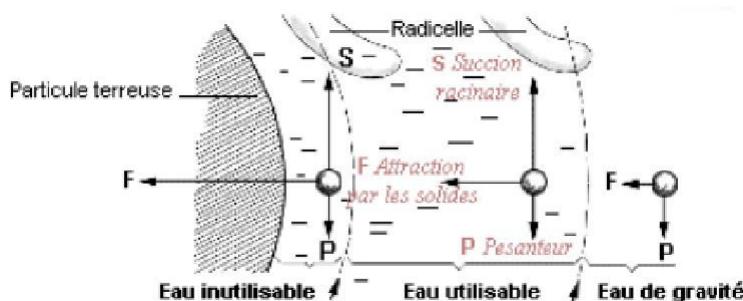


FIGURE 1.3 – La particule d'eau subit 3 forces principales dans le sol : son propre poids ( $\vec{P}$ ), la force de capillarité due à la proximité du grain ( $\vec{F}$ ) et la force de succion des radicelles des racines ( $\vec{S}$ ) ([Soltner, 1989]).

Le ratio entre ces 3 forces définit l'état de l'eau dans le sol. Lorsque la quantité d'eau dans le sol est faible, la particule d'eau est retenue à la surface des grains de sol par la force de capillarité  $\vec{F}$ , l'eau est dite liée au sol. Dans cet état hydrique les racines n'ont pas une force de succion  $\vec{S}$  suffisante pour extraire l'eau nécessaire à la plante, cette valeur d'humidité dans le sol est appelée le *point de flétrissement* (ou wilting point). Maintenant si il y a suffisamment d'eau pour ne pas être uniquement en régime lié, alors l'eau est dite utilisable et la force de succion des racines est suffisante pour alimenter la plante en eau. La quantité d'eau que le sol est capable de stocker sans qu'il n'y ait d'écoulement gravitaire est la *capacité au champs* (ou field capacity). Au delà de cette valeur d'humidité du sol, la gravité permet à l'eau de percoler dans le sol. Une fois les pores remplis arrive la *saturation*.

## 1.2. QU'EST CE QUE L'HUMIDITÉ DU SOL ?

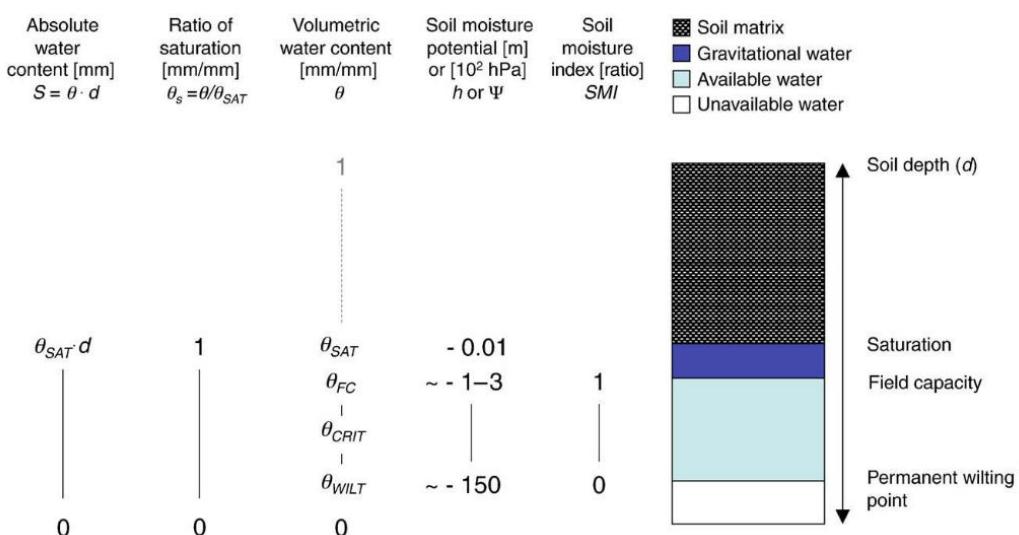


FIGURE 1.4 – Différentes métriques sont utilisées pour caractériser l'état hydrique du sol (figure tirée de [Seneviratne et al., 2010]).

La Figure 1.4 représente les grandeurs usuellement utilisées pour caractériser l'état du sol. De gauche à droite : l'équivalent de la couche d'eau dans l'épaisseur donnée ; l'état de saturation (1 pour saturé 0 pour sec) ; l'état du sol selon les différentes valeurs seuils ; le potentiel de liaison de l'eau avec le sol ; le SMI (ou SWI), équivalent de l'état de saturation mais entre le point de flétrissement et la capacité au champs, soit la réserve utile pour la plante. Considérons maintenant la dépendance des forces induites sur les particules d'eau à la granulométrie du sol, alors les paramètres de wilting point, capacité de champs et de saturation sont variables en fonction de la nature du sol :

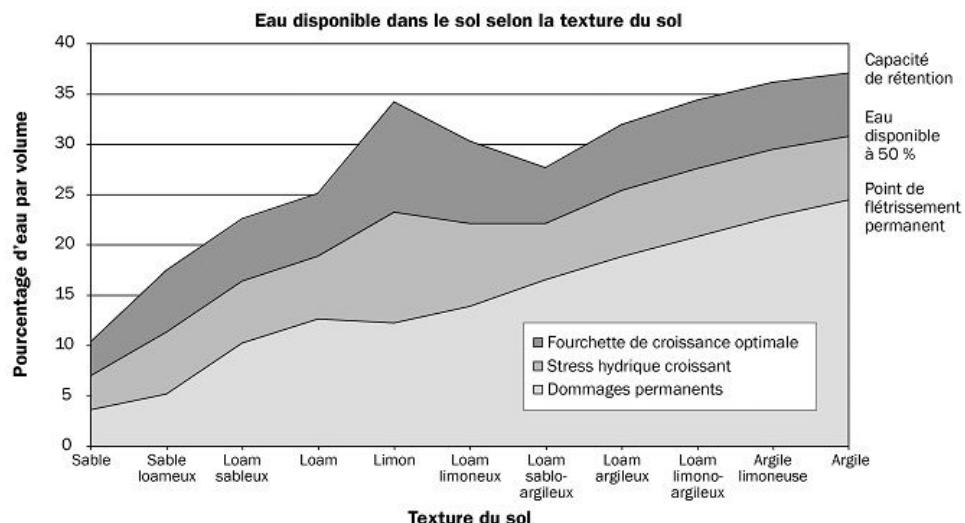


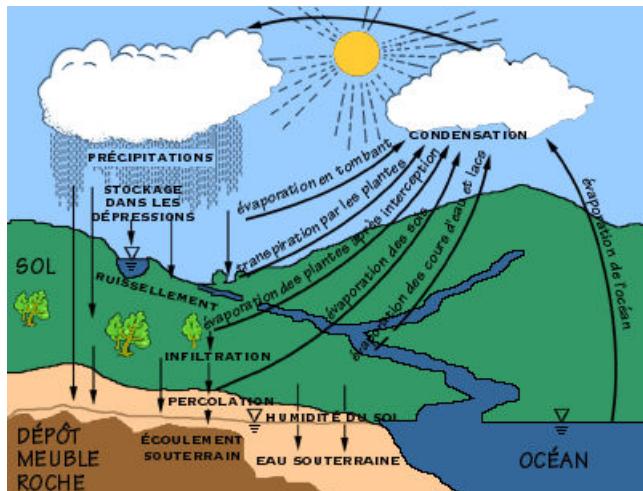
FIGURE 1.5 – La texture du sol conditionne sa capacité à retenir de l'eau dans le sol [Rebecca et al., 2015].

Sur la Figure 1.5 on peut voir l'évolution des 2 grandeurs présentées précédemment, la capacité au champs et le point de flétrissement. On peut alors remarquer que plus le sol est sableux, donc avec de grain grossier, moins il peut stocker d'eau. On peut remarquer aussi que la quantité d'eau disponible pour la plante est relativement homogène sauf pour les sol limoneux.

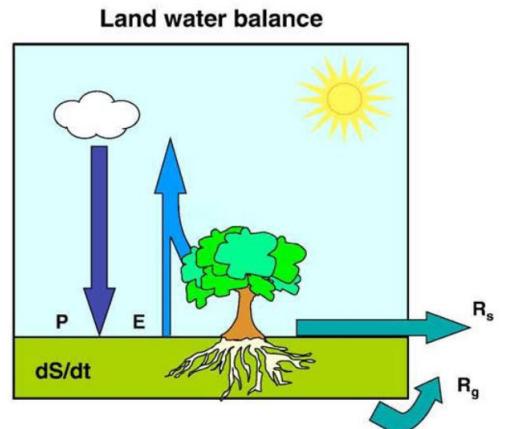
## 1.3 L'humidité du sol intervient dans...

### 1.3.1 ... le cycle de l'eau et la balance énergétique

#### 1.3.1.1 Rôle dans le cycle de l'eau



(a) Le cycle de l'eau



(b) Partitionnement de l'eau à la surface.

FIGURE 1.6 – Généralités sur le cycle de l'eau.

Le cycle de l'eau, Figure 1.6a, représente les échanges entre 4 principaux réservoirs de ressource d'eau : les mers et océans, les eaux continentales, la biosphère et l'atmosphère. L'eau résultant de la fonte des glaces/neiges et des précipitations est en partie infiltrée dans le sol. Une autre partie ruisselle le long des pentes, alors qu'une autre est absorbée par la biosphère locale. Une partie de l'eau ruisselante peut former des cours d'eau allant directement se déverser jusque dans d'autres réservoirs, ou bien indirectement en s'infiltrant d'abord dans le sol puis se déversant dans lacs, mers et océans.

Les flux d'eau de ce cycle sont représentés Figure 1.6b :

$$\frac{dS}{dt} = P - ET - R_s - R_g \quad (1.2)$$

avec ET pour l'évapotranspirations, P les précipitations, S les stocks de subsurface, R<sub>s</sub> les écoulements continentaux et R<sub>g</sub> le drainage. En terme de proportion, en moyenne annuelle sur l'ensemble des surfaces émergées, 65% des précipitations s'évaporent, 24% ruissent et 11% s'infiltrent ([Trenberth et al., 2007]).

L'humidité du sol intervient dans chacune des composantes de cette équation :

- **Les précipitations (P)** : Les précipitations sont les hydrométéores solides ou liquides tombant à la surface de la Terre. Leur proportion est globalement de 7/9 sur les océans ( $\sim 386^3 \text{ km}^3$ ) et de 2/9 ( $\sim 114^3 \text{ km}^3$ ) sur les surfaces continentales. Le lien entre précipitation et humidité du sol est assez direct, car sauf évaporation avant le sol, ruissellement de surface ou encore interception par la canopée, les précipitations alimentent l'humidité du sol. Cependant, les **rétroactions entre humidités du sol et précipitations** sont encore à l'étude (abordées dans la suite ici).
- **L'évapotranspiration (ET)** : L'évapotranspiration est le volume d'eau transféré de la surface du sol vers l'atmosphère ( $\sim 65\%$  des précipitations continentales). Elle est composée de l'évaporation issue de l'eau de surface (humidité du sol, interception, eau libre,...)

et de la transpiration de la végétation par les stomates. L'humidité du sol contribue donc directement au **potentiel évaporatif** du sol en alimentant le processus en eau. De plus, en conditionnant la **croissance de la végétation**, l'humidité du sol participe directement au bon développement et à la transpiration de cette dernière.

- **Le ruissellement de surface (Rs)** : Le ruissellement de surface est la partie de l'eau qui s'écoule à la surface du sol, dans le sens de la pente. Ce flux ruisselle jusqu'à atteindre un cours d'eau ou une étendue d'eau libre, proportion qui intervient notamment dans le **débit des rivières**. On distingue 2 types de ruissellement : (i) lorsque la capacité d'infiltration du sol est atteinte (le ruissellement hortonien) et (ii) lorsque le sol est saturé.
- **Le drainage (Rg)** : La partie de l'eau s'étant infiltrée dans le sol, qui n'a pas été évaporée en surface ou absorbée par les racines puis transpirée, peut contribuer à la **recharge de nappes souterraines** et au **débit des rivières** (notamment le maintien du débit d'étiage). Ce processus est dépendant de la conductivité hydraulique du substrat, qui peut être grande (en entraînant un drainage rapide) dans le cas de présences de macropores [Beven and Germann, 2013], ou faible (en entraînant un drainage lent) lors de la présence de lentilles argileuses [Parlange et al., 1989].

### 1.3.1.2 Rôle dans la balance énergétique de surface

L'évapotranspiration intervient aussi dans la balance énergétique (équation de la Figure 1.8). Même si l'humidité du sol n'apparaît pas directement dans l'équation, elle conditionne de nombreux processus dont l'évapotranspiration ( $E$ ), la capacité thermique du sol ou encore l'albédo de surface.

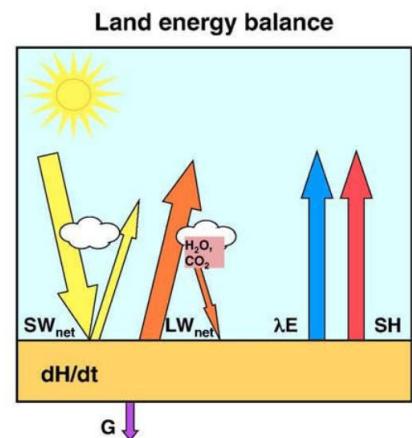
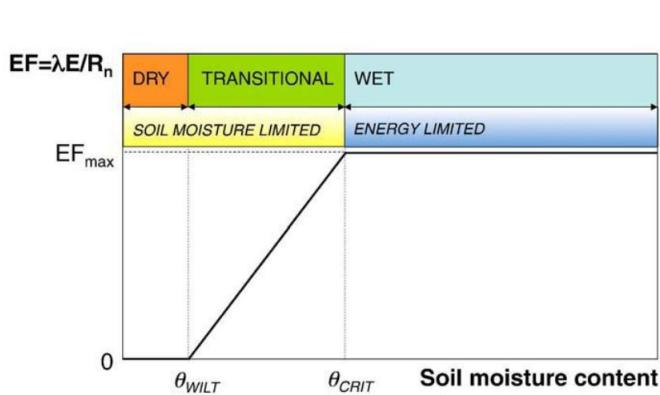


FIGURE 1.7 – Influence de l'humidité du sol sur la fraction éparorative

$$\text{FIGURE 1.8} - \left( \frac{dH}{dt} \right) = R_n - \lambda E - SH - G$$

Étudions l'influence de l'humidité du sol sur la fraction d'évaporation  $EF$  (pour Evaporation fraction, ratio entre l'énergie latente ( $\lambda E$ ) et le rayonnement net  $R_n$ ). Cette interaction initialement soulevée par [Budyko, 1956], puis récemment revu par [Seneviratne et al., 2010] représente la part d'énergie latente dans le transfert d'énergie à la surface du sol. Si cette échange est uniquement sensible (échange de chaleur uniquement), alors l' $EF$  sera proche de 0. Si au contraire une grande partie de ce transfert se fait par changement d'état de l'eau, énergie latente, alors l' $EF$  atteint une limite haute l' $(EF_{max})$ . On peut alors mettre en avant deux types de régimes. Le premier, en jaune sur la Figure 1.7, relatif à des climats plutôt secs et tempérés.

Dans cette fourchette, l'*EF* est principalement pilotée par l'humidité du sol car c'est le facteur limitant (fort rayonnement solaire et faible cumul pluviométrique). Le second régime, en bleu, concerne les régions où l'apport en eau n'est pas le facteur limitant mais plutôt l'énergie de rayonnement disponible. L'humidité du sol a un fort impact sur la fraction évaporative, et donc sur la balance énergétique, dans les régions à fort rayonnement et à climat sec. La région Sahélienne est typiquement un régime de transition d'un climat humide vers un climat sec. A ce titre, le rôle de l'humidité du sol dans cette région est important.

### 1.3.1.3 Les rétroactions humidité du sol ⇌ atmosphère

Différentes expériences de modélisation ont été réalisées pour étudier la sensibilité des modèles à des variations d'humidité sur l'atmosphère. Parmi ces études, l'expérience GLACE (Global Land-Atmosphere Coupling Experiment, [Koster et al., 2004]) a montré que certaines régions du monde montraient un fort couplage entre humidité du sol et atmosphère. La Figure 1.9 représente les zones géographiques où la sensibilité de l'atmosphère aux variations d'humidité du sol sont importantes. On note que les zones de transition climat sec/humide ont un fort couplage ("hotspot", tâche rouge et jaune sur Figure 1.9). (explication Figure 1.7).

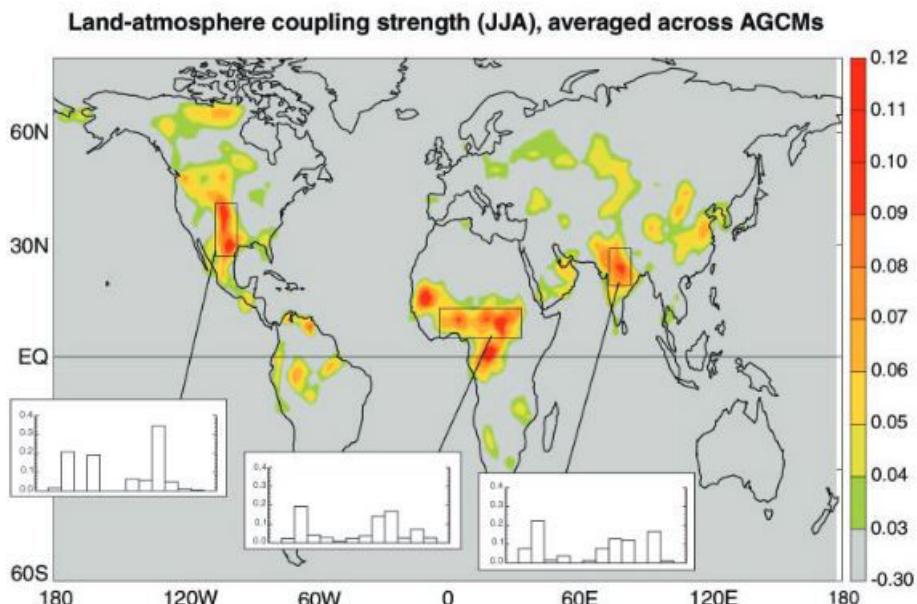
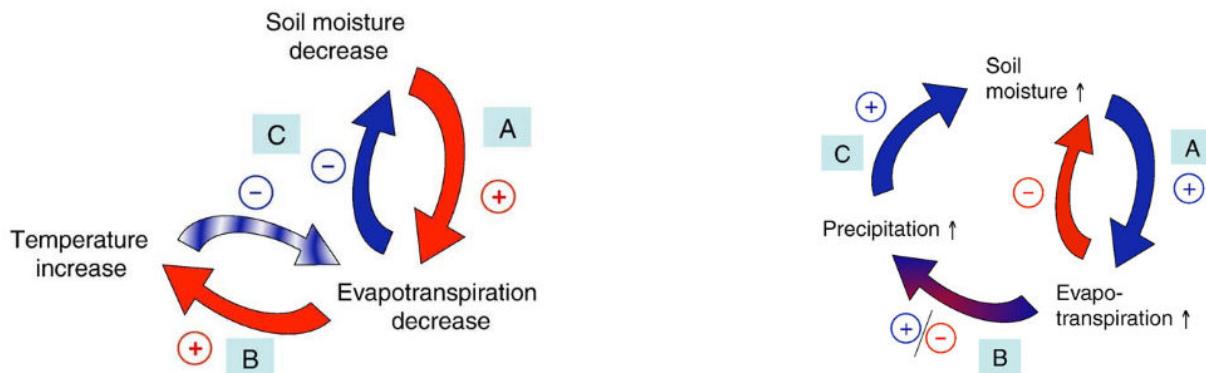


FIGURE 1.9 – Résultat de l'expérience GLACE qui met en avant les régions du monde où les couplages sol/atmosphère sont importants, [Koster et al., 2004]

Les processus mis en jeu ici sont relativement complexes, cependant, [Seneviratne et al., 2010] en présente une analyse simplifiée pour mieux appréhender les interactions entre humidité du sol et température (encart gauche) ou précipitation (encart droit) :



(a) Une **diminution** de l'humidité dans le sol aura un couplage positif sur l'ET dans le sens où cela diminuera la quantité d'eau mise à disposition pour l'ET (flèche rouge lien A). Si l'évapotranspiration diminue, la chaleur latente diminue aussi et donc la chaleur sensible augmente (flèche rouge B). Une hausse de chaleur sensible aura pour conséquence d'augmenter la tension de vapeur saturante (Loi de Clausius Clapeyron), et donc le potentiel d'évapotranspiration ce qui va **diminuer** l'humidité du sol..

(b) Une augmentation des précipitations augmentera inexorablement l'humidité du sol (lien C). Une augmentation de l'humidité du sol aura pour conséquence de mettre à disposition plus d'eau pour l'évapotranspiration, qui augmentera donc si le rayonnement le permet (lien A flèche bleue). Si l'ET augmente, cela asséchera le sol (lien A flèche rouge). L'impact de l'ET sur les précipitations est encore mal connu vu le nombre de processus mis en jeu (lien B) [Boé and Terray, 2014].

FIGURE 1.10 – Rétroaction de l'humidité du sol avec la température et l'évapotranspiration.

### 1.3.2 ... les grands cycles biogéochimiques

L'humidité du sol intervient enfin au cœur de la biosphère, et influe donc de nombreux cycles biogéochimiques. En agissant sur l'activité microbienne, l'humidité du sol agit directement sur les grands cycles de l'azote (N) [Pastor and Post, 1986], du phosphore (P) [Sparling et al., 1987] et du potassium (K) [Kuchenbuch et al., 1986], et sur leur potentiel assimilable par les plantes [Davidson, 1969].

L'humidité du sol est aussi un facteur important dans le cycle du carbone. Le sol est un réservoir important de carbone, avec un stock estimé autour de 2500 Gt [Lal, 2008], composé de 1550 Gt sous forme de matière organique et 950 Gt sous forme inorganique. Le sol représente donc 80% du carbone contenu dans l'écosystème terrestre qui contient 3170 Gt (les autres 20% étant contenu principalement dans les plantes et les animaux). En agissant sur la photosynthèse [Schneider and Childers, 1941], la décomposition de matière organique ou encore le taux de respiration [Orchard and Cook, 1983], l'humidité du sol est partie intégrante du cycle du carbone.

## 1.4 Méthodes d'estimation de l'humidité du sol

Il existe 3 méthodes principales pour estimer le taux d'humidité dans le sol : les mesures terrain, les modèles numériques et la télédétection.

### 1.4.1 La mesure *in-situ*

La mesure *in-situ* permet d'avoir la meilleure précision de l'humidité et sert souvent de référence. Il existe différents types de mesures *in-situ* :

- La méthode directe : La méthode qui permet de mesurer l'humidité du sol avec la meilleure précision est la gravimétrie. Le principe de cette méthode est de prélever un échantillon de sol dont on veut mesurer le contenu en eau (Figure 1.11). On le pèse, on le sèche (dans une étuve à 105 °C pendant 48h) et on le pèse de nouveau. La différence de masse sera donc l'eau qui s'est évaporée. L'avantage est donc sa précision, mais cette méthode est relativement coûteuse en temps et sa méthode est destructive.



(a) Fosse pour prélèvement d'échantillons.



(b) Les prélèvements de sol sont effectués à différentes profondeurs.

FIGURE 1.11 – Mesure de l'humidité du sol par gravimétrie.

- La méthode indirecte : Le principe ici est d'utiliser des proxy de l'humidité du sol facilement mesurable. La présence d'eau dans le sol modifie sa constante diélectrique, ainsi les méthodes électromagnétiques peuvent servir à estimer l'humidité du sol. On référence usuellement : les sondes Time Domain Reflectometry (TDR) qui mesurent le temps de parcours entre 2 tiges métalliques plantées dans le sol, ou encore les sondes capacitatives. Mais il existe d'autres méthodes telles que les sondes à neutrons, tensiomètres...

L'intérêt de ces méthodes est leur précision et sur la possibilité d'automatiser d'acquisition. Le problème majeur est que ce sont des mesures ponctuelles donc difficiles à spatialiser. Il existe un site financé par l'ESA, l' International Soil Moisture Network (ISMN), qui centralise les données d'humidité du sol issues de mesures *in-situ* à travers le monde (voir Figure 1.12).

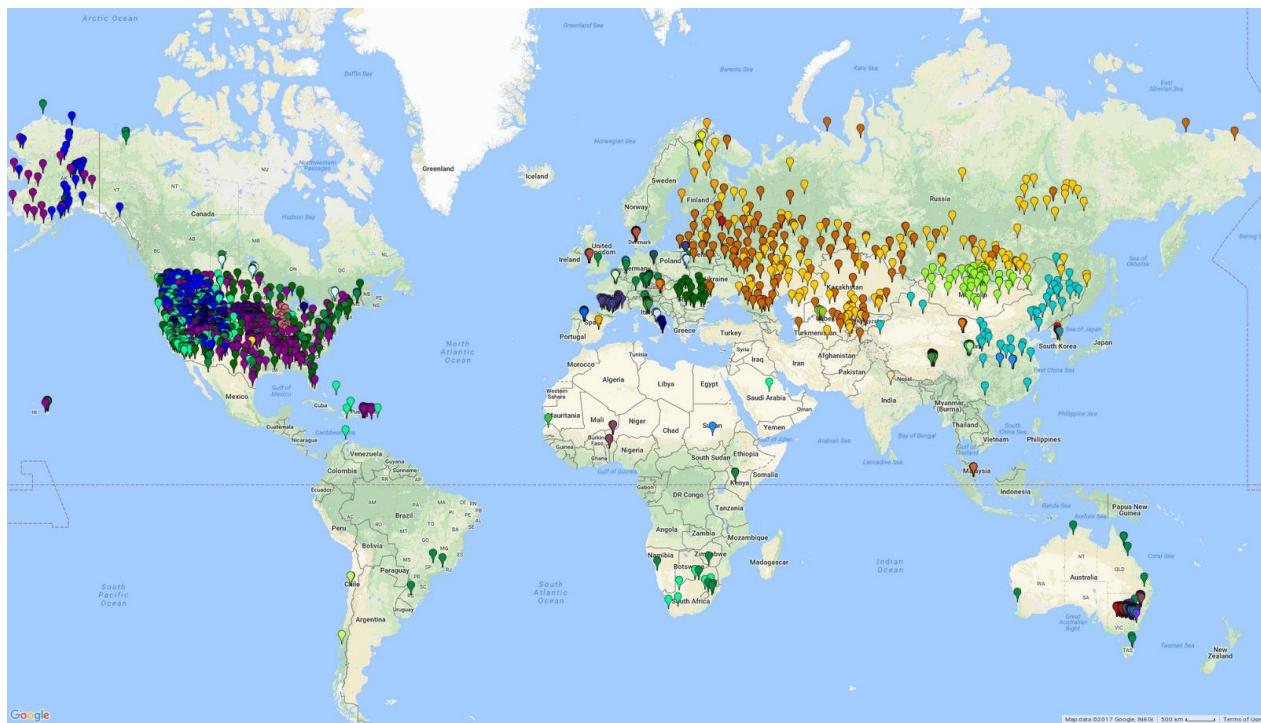


FIGURE 1.12 – Etat du réseau de l'ISMN le 25 Octobre 2017.

On remarque alors que les sondes sont très inégalement réparties sur l'ensemble des continents (réseau très dense aux Etats-Unis et très faible en Amérique du Sud). Or nous avons vu précédemment que les zones où les variabilités du sol avait un fort impact, étaient dans les régions de transitions climatiques. On retrouve bien les sondes AMMA-CATCH au Bénin et Niger, et plus récemment les sondes au Sénégal et en Éthiopie, mais cela reste peu au vue de la surface des "hotspot" de la Figure 1.9.

### 1.4.2 Les modèles de surface

Les modèles de surface, usuellement appelés Land Surface Model (LSM), ont pour objectif de représenter les processus physiques d'échanges entre le sol et l'atmosphère en implémentant numériquement les équations mathématiques des lois physiques ou des descriptions conceptuelles. Ces schémas ont été initialement créés pour modéliser les flux d'eau et d'énergie entre la surface et l'atmosphère. Ils s'intéressent généralement à la partie superficielle du sol (généralement entre la surface et 2-5m de profondeur). On classe ces modèles selon 3 grandes générations, de la description la plus simple à la plus détaillée.

Le premier modèle de surface a d'abord été implémenté dans un modèle climatique en 1969 par [Manabe, 1969]. Ce type de modèle, dit de première génération, est synthétisé par [Pitman, 2003] (Fig 1.13a). Il décrit la balance énergétique par des équations conceptuelles et considère le sol comme un simple réservoir type "bucket". Ici, il y a évaporation lorsque l'eau dans le sol est suffisante et le réservoir ne se remplit que si les précipitations sont supérieures à l'évaporation. Si le réservoir est trop plein, il "déborde" et on a alors du ruissellement de surface.

En 1978, le modèle de Deardorff (1977), inspiré du "force-restore" de [Blackadar, 1976], implémente une couche homogène sur le sol modélisant la végétation, ce sont les modèles de seconde génération (Fig 1.13b). Ces derniers permettent d'intégrer le processus de photosynthèse et ainsi de dynamiser l'évapotranspiration ou encore l'interception du rayonnement incident par la canopée. Ainsi en fonction de l'année, la résistance stomacale ou encore le LAI évolue. On

peut citer comme exemple de modèles de seconde génération ISBA, BATS, SiB, ... La troisième génération de modèle est apparue fin 80. Ces derniers modélisent les cycles énergétiques, hydrologiques et du carbone, ainsi que les interactions entre eux. On citera pour exemple l'évolution ISBA-A-gs, SiB2 ou encore ORCHIDEE.

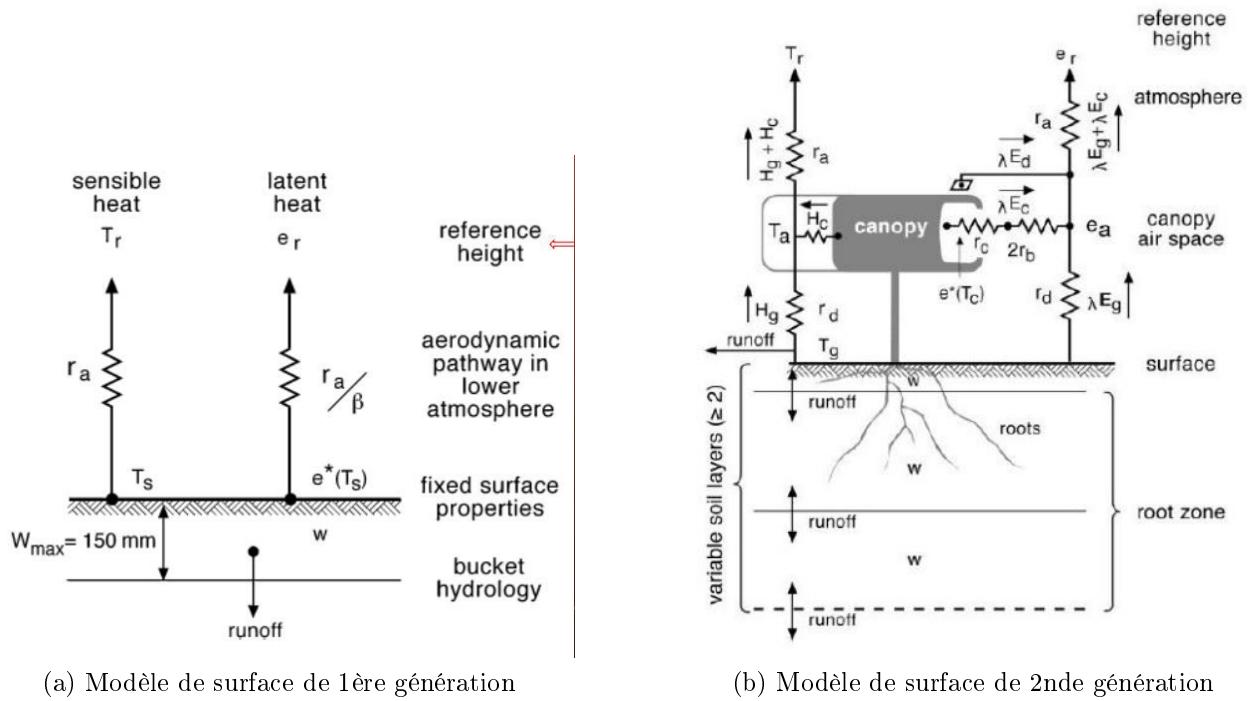


FIGURE 1.13 – Niveaux de complexité différent entre 2 modèles de surface (schéma de [Pitman, 2003]).

### 1.4.3 La télédétection spatiale

La télédétection est l'observation (*détection*) d'un milieu, un processus, un phénomène, sans contact direct (*télé*). Cette méthode prend en compte une notion de distance, de changement d'échelle. Ainsi, dans l'exemple de l'observation de la Terre par satellite, les phénomènes et processus observés sont différents de ceux étudiés en laboratoire ou sur le terrain. Cela permet de prendre du recul et d'analyser globalement les processus. Pour effectuer ces observations, des instruments de mesure embarqués sur satellite enregistrent des informations via différents capteurs mesurant l'énergie d'un rayonnement électromagnétique émis ou réfléchi, ces informations sont ensuite transmises sur Terre puis traitées et analysées. On classe la nature de la mesure selon son caractère passif ou actif. Passif revient à observer le rayonnement naturel de la Terre (ex : radiométrie), alors qu'actif émet un signal et observe ce qui lui revient (ex : RADAR). Les débuts de la télédétection appliquée à la mesure de l'humidité du sol datent des années 1980 (Figure 1.14). Majoritairement basées sur des radiomètres (passif, en jaune sur Figure 1.14) et des diffusomètres radar (actif, en bleu sur Figure 1.14) dans les micro-ondes, les différentes technologies de capteurs ont permis de grandes avancées dans l'estimation de l'humidité du sol dans la couche superficielle (0-5 cm). En effet, le rayonnement micro-onde est sensible aux variations diélectriques du milieu, phénomène mis en jeu lors des variations d'humidité du sol. Pour plus de détails sur la théorie des rayonnements micro-ondes se référer à l'**Annexe A**.

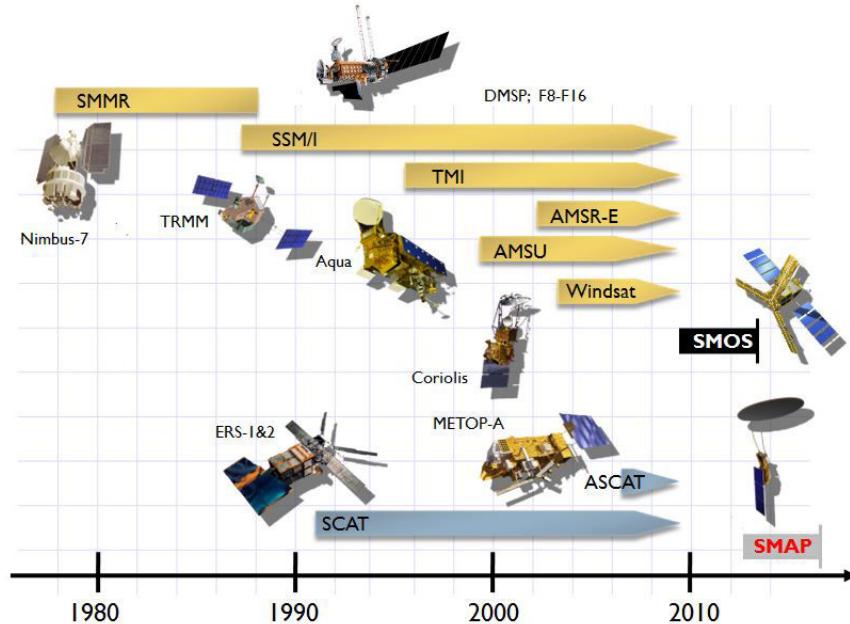


FIGURE 1.14 – Historique des missions satellitaires liées à l'humidité du sol. (<http://esa-soilmoisture-cci.org/>).

## 1.5 Problématique de l'estimation de l'humidité en zone racinaire

La Figure 1.15 représente la problématique liée l'estimation de l'humidité en zone racinaire, la zone d'intérêt de cette étude (rectangle rouge). En effet, les mesures *in-situ* (rectangle vert) sont ponctuelles et la télédétection micro-onde (rectangle bleu) n'accède qu'à la partie superficielle du sol. Afin d'accéder à l'humidité sur des couches plus profondes, il est nécessaire d'utiliser des modèles de surface (zone hachurée violette). Or la modélisation a aussi ses inconvénients qui sont liés à ses incertitudes (physique des équations, paramétrisations,...) et aux incertitudes sur les forces qui les alimentent.

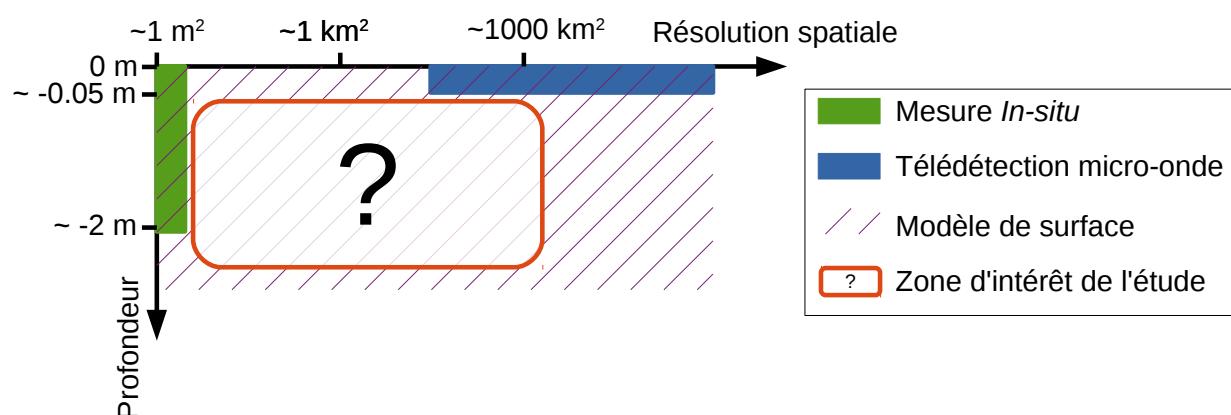


FIGURE 1.15 – Problématique de résolution relative au différentes méthodes d'estimation d'humidité du sol.

# Chapitre 2

## Estimation de l'humidité du sol en Afrique de l'Ouest : Le triptyque In-situ/Télédétection/Modélisation

---

<b>2.1</b>	<b>Introduction</b>	<b>32</b>
<b>2.2</b>	<b>Une "bonne estimation" de l'humidité du sol ?</b>	<b>32</b>
<b>2.3</b>	<b>Mesures in-situ : l'observatoire AMMA-CATCH comme référence</b>	<b>34</b>
2.3.1	Site du Bénin	35
2.3.2	Site du Niger	37
2.3.3	Quelle variabilité de l'humidité du sol entre les sondes in-situ ?	38
<b>2.4</b>	<b>Télédétection spatiale : SMOS pour les mesures globales</b>	<b>43</b>
2.4.1	Comment estimer l'humidité du sol depuis l'espace ?	43
2.4.2	Évaluation de SMOS	47
2.4.2.1	SMOS au Bénin	47
2.4.2.2	SMOS au Niger	49
2.4.3	Limitations	51
2.4.3.1	Impact des RFI	51
2.4.3.2	Problématique du sous échantillonnage de SMOS	54
<b>2.5</b>	<b>Modélisation numérique : SURFEX et API pour la simulation large échelle</b>	<b>56</b>
2.5.1	Un modèle à base physique : SURFEX	56
2.5.2	Un modèle empirique : le modèle API	59
2.5.3	Comparaison SURFEX/API	60
2.5.4	Impact des incertitudes des précipitations sur les simulations d'humidité	65
<b>2.6</b>	<b>Résumé et conclusion</b>	<b>72</b>

---

## 2.1 Introduction

La quantification des grands réservoirs du cycle de l'eau (voir Figure ?? a)) est un véritable enjeu, et ce à différentes échelles. Estimer les réserves et les transferts de ces grands réservoirs est indispensable pour comprendre leurs évolutions, en particulier dans le contexte actuel de réchauffement climatique. Cependant, même s'il est aujourd'hui possible d'estimer localement la plupart des compartiments de ce cycle, l'échelle régionale, voire globale, reste encore incertaine.

Les problématiques liées à la représentation régionale sont d'autant plus importantes en Afrique de l'Ouest que les ressources et l'économie de la région sont très sensibles aux variabilités climatiques. En effet, les caractéristiques spatiale et temporelle de la mousson africaine ont un impact très important sur les sociétés subsahariennes. La quantité annuelle de précipitation et surtout la répartition temporelle des pluies jouent un rôle essentiel sur les rendements des cultures et a donc un impact socio-économique important dans la région.

La problématique des observations de terrain est importante en Afrique de l'Ouest. Que ce soit directement au travers la pluie avec les pluviomètres (1 pour 10 000 km<sup>2</sup>) ou bien les sondes d'humidité du sol (moins de 10 sites), cette région du monde fait face à une faible densité d'instrumentation *in-situ*. Renseigner les variations des compartiments du cycle de l'eau à grande échelle dans cette région est donc relativement complexe par manque de mesures *in-situ*.

Dans les régions semi-arides la disponibilité en eau est très variable, temporellement et spatialement (mousson africaine). L'étude de l'impact de cette variabilité sur la croissance de la végétation nécessite donc au préalable de pouvoir représenter cette disponibilité en eau à différentes échelles.

L'idée de ce chapitre est d'évaluer les trois différentes méthodes d'estimations d'humidité du sol que sont la mesure *in-situ*, la télédétection spatiale et la modélisation numérique. Tout d'abord, les outils statistiques qui sont utilisés afin de quantifier les comparaisons entre sources de données sont présentés. Puis, les données *in-situ* issues de l'observatoire AMMA-CATCH sont analysées. Est ensuite abordé le principe de mesure de l'humidité du sol par radiométrie micro-onde par le satellite SMOS ainsi que ses limites. Enfin une étude sur la qualité des modélisations numériques est effectuée via deux modèles de complexité différente : le schéma de surface SURface EXternalisée (SURFEX) et le modèle Antecedent Precipitation Index (API).

## 2.2 Une "bonne estimation" de l'humidité du sol ?

La méthode de mesure la plus directe de l'humidité du sol est la mesure par prélèvement d'échantillon (voir 1.4.1). Cependant cette méthode est lente, destructive, comporte des incertitudes quant à la méthode d'échantillonnage, elle n'est pas automatisable et surtout, elle reste très locale. D'autres méthodes *in-situ*, comme les sondes CS616 utilisées sur l'Observatoire AMMA-CATCH permettent de faire une acquisition toutes les 30 minutes, et de manière automatisée. Ces sondes permettent de suivre l'évolution de la variation de constante diélectrique dans le sol, et donc de retrouver l'humidité. Malgré quelques limitations (limite du contact tige/sol ou encore problème de calibration), ce sont les séries temporelles issues de ces sondes qui serviront de "référence" pour évaluer les différentes estimations basées sur des modèles ou de la télédétection spatiale.

Les scores statistiques permettant de comparer deux séries temporelles sont assez nombreux. Dans la review [Loew et al., 2017], les auteurs font une description détaillée des différentes définitions de ces différents scores. Cependant quelques-uns d'entre eux sont usuellement employés pour ce qui est de l'humidité du sol [Entekhabi et al., 2010b] :

- Le coefficient de corrélation **R**

Selon le Larousse 2016 : *Le coefficient de corrélation est un nombre mesurant la dépendance entre deux caractères quantitatifs.* Sa formule mathématique est la suivante :

$$R_{XY} = \frac{Cov(XY)}{\sigma_X \sigma_Y} \quad (2.1)$$

avec :

- $Cov(XY)$  la covariance entre les deux variables XY
- $\sigma_X$  et  $\sigma_Y$  les écart-types de chacune des variables.

Plus la valeur de  $R$  est proche de -1 ou de 1, plus la relation entre les 2 valeurs analysées est linéaire dans le cas de Pearson (car dans le cas de Spearman c'est la monotonie de la relation qui est testée). Ainsi lorsque le R est proche de 0, la relation entre les 2 variables testées est faible. Un paramètre très important dans ce type de relation est la p-value. Cette valeur teste l'hypothèse de non-corrélation dans ce cas-là. Sa valeur est la probabilité d'avoir une corrélation aussi grande que celle obtenue si l'on utilisait des variables aléatoires. Ainsi plus la p-value est faible, plus la relation de corrélation est significative. Dans cette étude (sauf précision) les corrélations présentées sont toutes à une p-value inférieure à 0.05.

On utilisera donc la corrélation comme outil pour quantifier la similitude avec les mesures *in-situ*.

- L'erreur quadratique moyenne **RMSE**, et sa version débiaisée **ubRMSE**

Le RMSE, pour Root Mean Square Error, est souvent utilisé pour étudier les différences entre une estimation et une observation. Dans le cas de l'humidité du sol, la différence est donc faite pour chaque pas de temps  $t$  de l'ensemble de points  $n$  (voir (2.2)), ces différences sont appelées les *résidus*. La valeur obtenue est de la même unité que les données comparées (la cible de SMOS en termes de RMSE est de  $0.04 \text{ m}^3 \cdot \text{m}^{-3}$ ).

$$RMSE_{XY} = \sqrt{\frac{\sum_{t=1}^n (X_t - Y_t)^2}{n}} \quad (2.2)$$

Cependant, le RMSE est très sensible au biais car il calcule la différence entre les points. Un autre score, le ubRMSE, pour unbiased RMSE, permet de comparer 2 séries temporelles dont le biais a été retiré au préalable. La relation s'écrit :

$$ubRMSE_{XY} = \sqrt{\frac{\sum_{t=1}^n ((X_t - \widehat{X}_t) - (Y_t - \widehat{Y}_t))^2}{n}} \quad (2.3)$$

- **Le biais**

Le biais est défini comme étant l'écart à la moyenne. Dans le cas ici on l'utilisera pour quantifier l'écart entre les moyennes des séries d'humidités estimées et les moyennes des mesures *in-situ* correspondantes.

$$Biais_{XY} = \widehat{X}_t - \widehat{Y}_t \quad (2.4)$$

Ce sont donc ces scores qui seront utilisés tout au long de cette étude afin de comparer les données entre elles.

## 2.3 Mesures in-situ : l'observatoire AMMA-CATCH comme référence

L'observatoire AMMA-CATCH est la composante observation de long terme ( $>10$  ans) du cycle de l'eau du programme AMMA. Les objectifs de ce service d'observation sont divisés en trois domaines. Le premier cherche à documenter la variabilité interannuelle des acteurs de la mousson africaine, par l'étude du comportement des systèmes convectifs et de leurs impacts sur le cycle hydrologique continental. Le second concerne l'étude de processus de la zone critique par la quantification des membres de l'équation du bilan hydrique (1.2). Enfin un accent particulier est mis sur la modélisation, que ce soit l'utilisation des données d'observations à des fins de validation ou de paramétrisation des modèles.

L'observatoire est implanté sur trois sites de méso-échelle (les zones encadrées en noir sur la carte a) Figure 2.1), au Mali, Niger et Bénin. L'intérêt de la distribution spatiale de ces sites de mesure réside dans la distribution latitudinale (entre  $8^{\circ}\text{N}$  et  $17^{\circ}\text{N}$ ), ce qui permet de travailler le long du très fort gradient dû à la mousson.

D'un point de vue de l'humidité du sol, l'observatoire a instrumenté ses trois sites en sondes d'humidité (voir losange violet sur a) Figure 2.1). Ce sont ces données qui vont être utilisées comme références (données avec le moins d'incertitudes) dans cette étude. Les sondes sont disposées à différentes profondeurs sur les premiers 1,5 m du sol. L'observatoire fait partie du réseau ISMN ([Dorigo et al., 2011]), voir carte 1.12. Ces sondes (principalement des Campbell CS616 et CS615) permettent d'observer l'évolution de la quantité d'eau à différentes profondeurs (Figure b) 2.1).

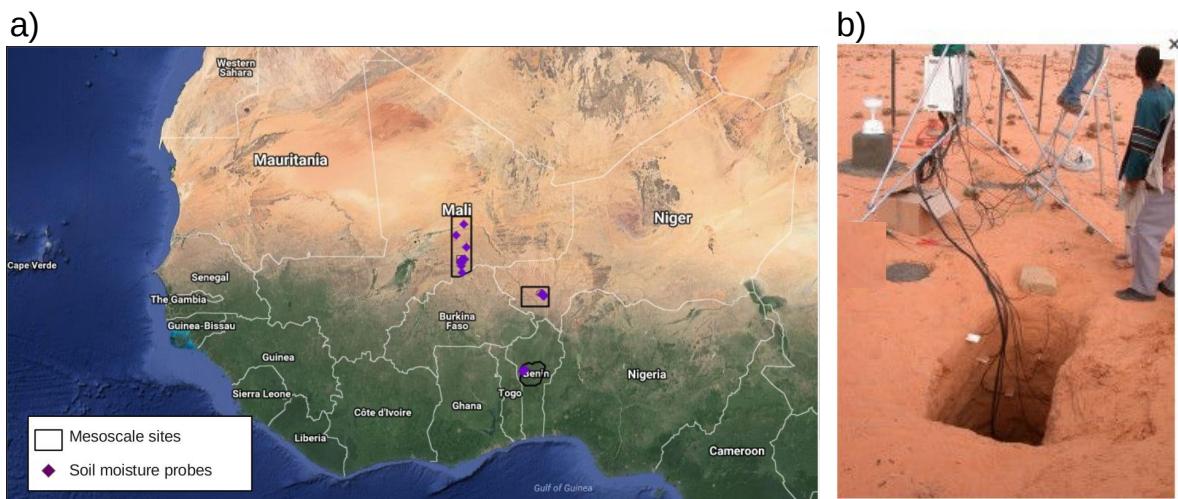


FIGURE 2.1 – En a) L'observatoire AMMA-CATCH avec la disposition des trois sites de mesures le long du gradient latitudinal sahélien (fond de carte GoogleMaps et shapefile issue de la BD AMMA-CATCH). En b) Exemple de fosse où les sondes ont été installées à différentes profondeurs (photo issue du site AMMA-CATCH).

### 2.3.1 Site du Bénin

La Figure 2.2 représente la disposition des 3 sites instrumentés situés au Nord Ouest du Bénin : Béléfoungou [9.80 ° N ; 1.72 ° E], Bira [9.83 ° N ; 1.72 ° E] et Nalohou [9.75 ° N ; 1.6 ° E] ([Galle et al., 2004], [Galle et al., 2007]). La base de données ESA CCI LandCover, Figure 2.3 décrit la zone comme composée majoritairement d'arbustes (shrubland), de forêts relativement éparses (mosaic tree) et de cultures pluviales (cropland rainfed).

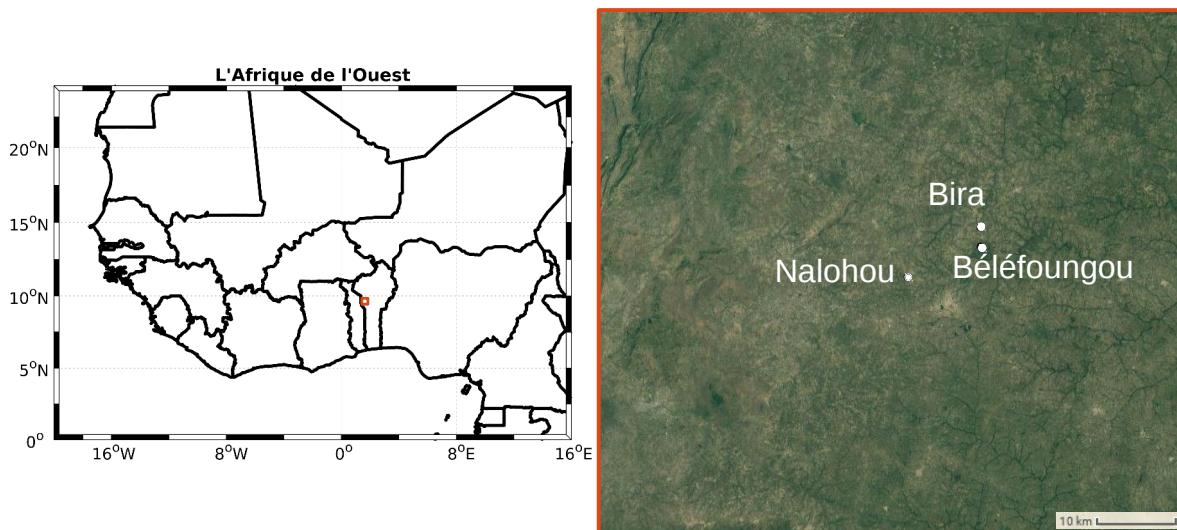


FIGURE 2.2 – Disposition des sites AMMA-Catch Bénin où sont mesurée l'humidité du sol.

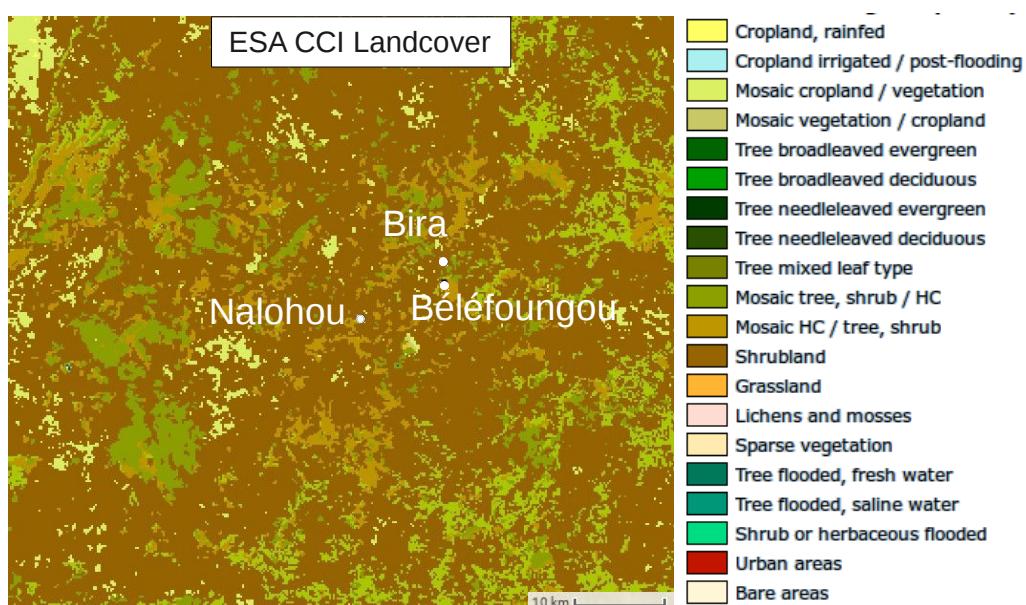


FIGURE 2.3 – Occupation du sol issue de la base de données ESA CCI LandCover pour le site de AMMA-CATCH Bénin.

Sur chacun de ces sites, plusieurs transects ont été installés selon la pente d'un versant. Disposés à des profondeurs différentes, l'ensemble des 8 profils mesurés (Nalohou haut, bas et milieu ; Bira haut et milieu ; Béléfoungou haut, bas et milieu) permettent d'effectuer une représentation de la dynamique de l'humidité du sol à l'échelle du site. Figure 2.4 représente l'humidité du sol en  $\text{m}^3.\text{m}^{-3}$  pour les différentes profondeurs. L'ensemble grisé correspond à l'ensemble des sondes, et la ligne noire, à la moyenne. En surface, la gamme d'humidité varie entre  $0.03 \text{ m}^3.\text{m}^{-3}$  pendant la saison sèche et jusqu'à  $0.45 \text{ m}^3.\text{m}^{-3}$  pendant la saison des pluies. Plus on descend en profondeur plus on voit apparaître des biais entre les sondes (l'ensemble gris est de plus en plus large). On observe donc que l'eau s'infiltra à plus d'un mètre de profondeur chaque année.

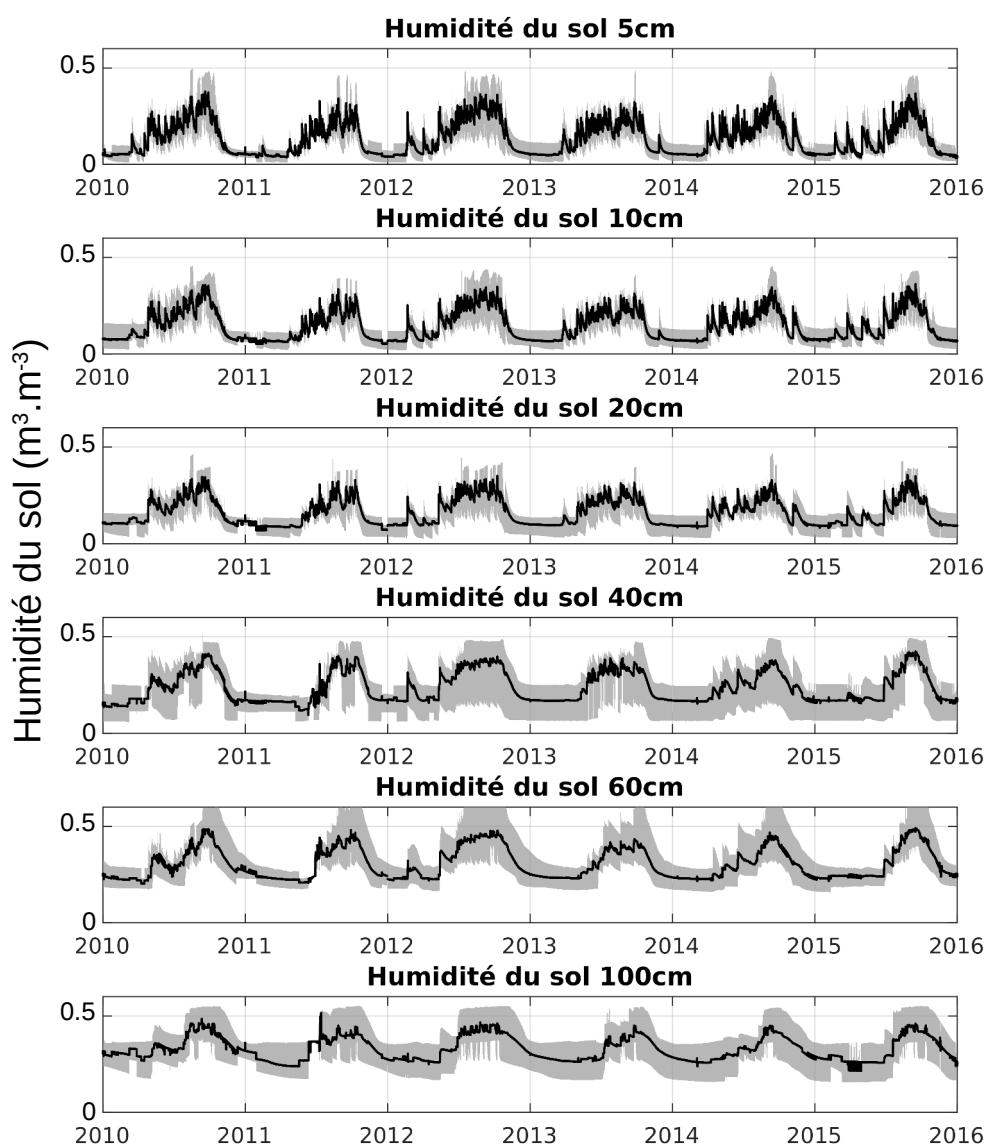


FIGURE 2.4 – Évolution de l'humidité du sol à différentes profondeurs pour les huit profils sur les three sites du Bénin. La moyenne est présentée en noire et l'enveloppe grise correspond à l'ensemble des sondes.

### 2.3.2 Site du Niger

Le site AMMA-CATCH du Niger se situe à 40 km à l'Est de Niamey, la capitale. Il est subdivisé en 3 sites : Wankama [13.65 ° N ; 2.63 ° E], Tondikiboro [13.55 ° N ; 2.70 ° E] et Banizoumbou [13.53 ° N ; 2.66 ° E] ([Pellarin et al., 2009], [Cappelaere et al., 2009]). La base de données ESA CCI LandCover, Figure 2.6, présente cette région du Niger comme étant composée majoritairement de prairies et de pâturages (grassland).

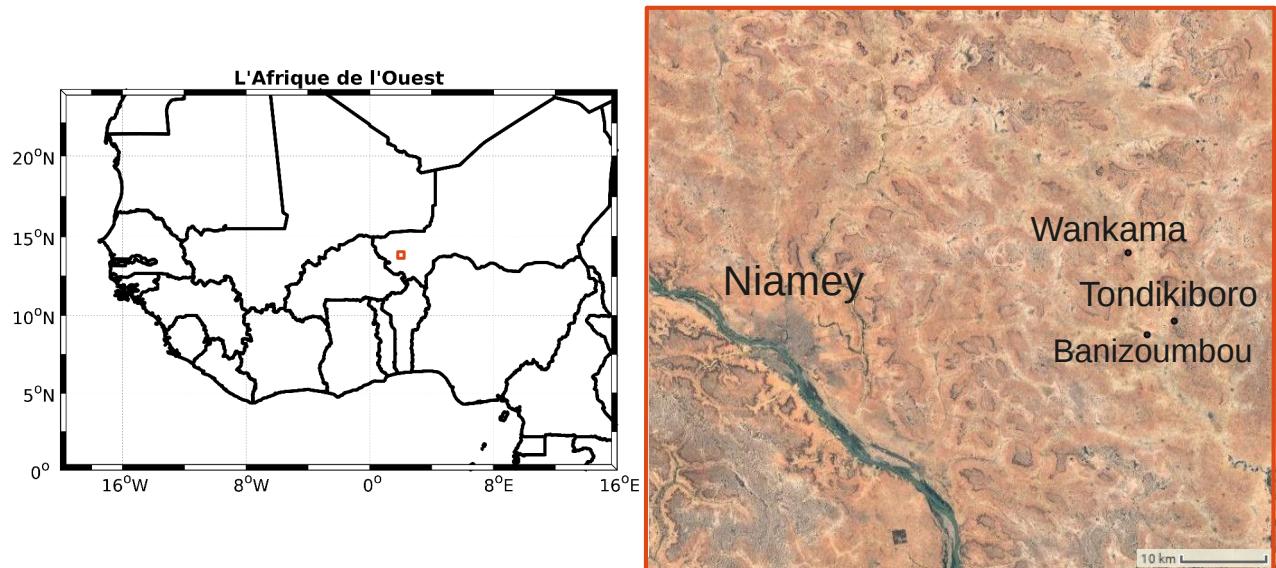


FIGURE 2.5 – Disposition des sites AMMA-CATCH Niger où sont mesurée l'humidité du sol.

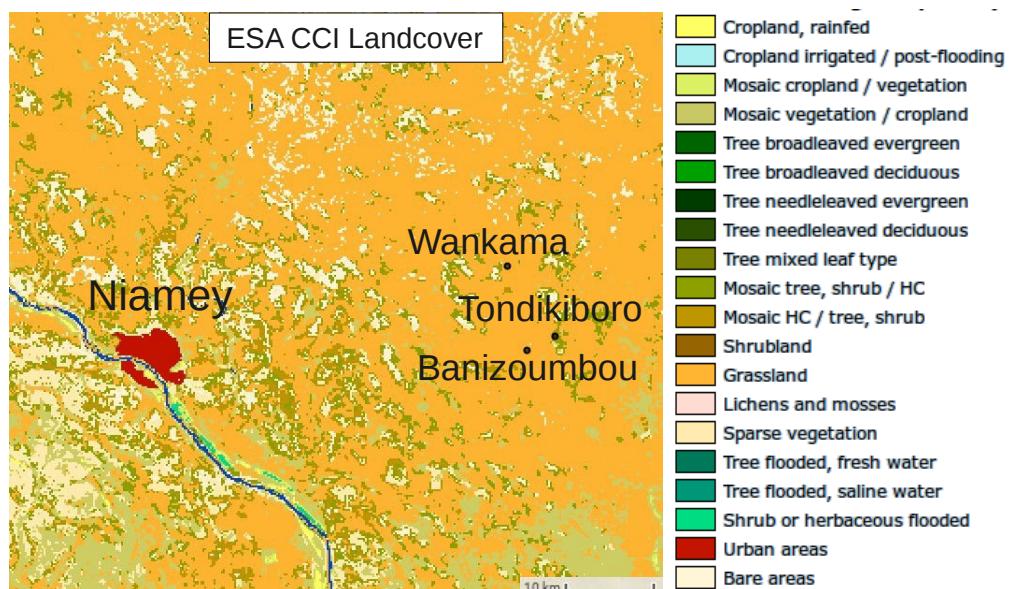


FIGURE 2.6 – Occupation du sol issue de la base de données ESA CCI LandCover pour le site de AMMA-CATCH Niger.

La Figure 2.7 présente les variations de l'humidité du sol mesurées entre 2010 et 2016 à différentes profondeurs (entre 5 et 120 cm). Ici uniquement les profils pour les champs en jachère (fallow) ou cultivés (millet) sont représentés, les sondes situées dans les ravines ne le sont pas ici (infiltration >10m [Descroix et al., 2012]). On observe ici que l'infiltration de l'eau est assez variable d'une année à l'autre. En effet, pour les années 2010, 2011 et 2015, l'eau n'atteint pas les 120 cm, alors que pour les autres années le front d'humectation descend plus en profondeur. On observe aussi la présence de "pause" infra-saisonnière où l'humidité diminue en pleine saison des pluies, comme en 2012 ou 2015.

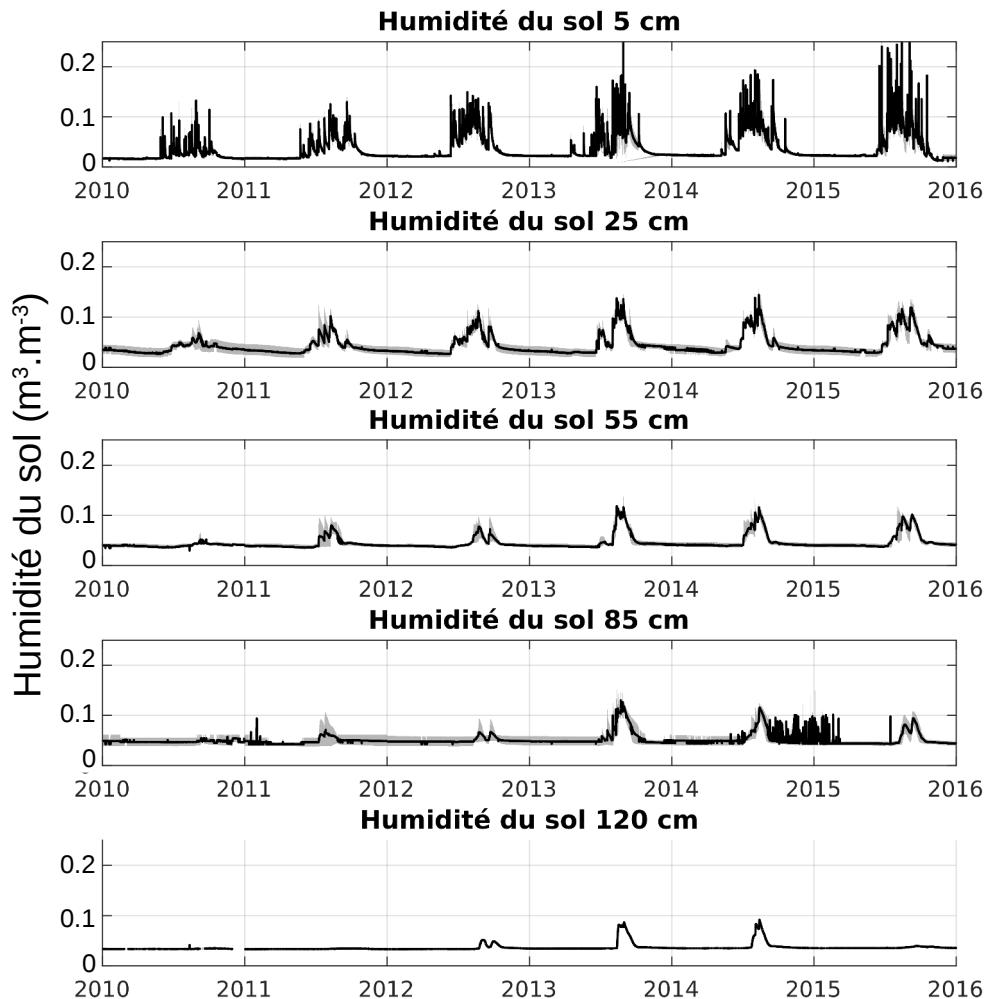


FIGURE 2.7 – Évolution de l'humidité du sol à différente profondeurs pour les six profils sur les trois sites. En noir la moyenne et l'enveloppe grise correspondent à l'ensemble.

### 2.3.3 Quelle variabilité de l'humidité du sol entre les sondes in-situ ?

Dans cette partie on se propose d'analyser statistiquement la dynamique spatiale de l'humidité du sol à partir des sondes *in-situ*. La quantification de l'hétérogénéité spatiale de la variabilité de l'humidité du sol d'une sonde à l'autre reste une question critique dans le domaine de la télédétection basse résolution. En effet, lorsque l'on parle d'humidité estimée à partir du rayonnement micro-onde, l'hétérogénéité de la scène mesurée pose la question de la représentativité de la mesure satellite micro-onde ( $25 \times 25$  km). La littérature documente abondamment le sujet pour différents types de sol et de végétation ([Sharma et al., 1980], [Sisson and Wierenga, 1981],

[Vieira et al., 1981], [Vachaud et al., 1985]). Les principaux facteurs influençant l'hétérogénéité spatiale de l'humidité du sol sont attribués à la topographie, aux propriétés hydrodynamiques du sol, à la présence de ruissellement, d'irrigation ou encore à la structure spatiale des épisodes pluvieux ([Hillel, 1987], [Kachanoski and Jong, 1988], [Jaynes and Hunsaker, 1989]).

Cependant, les facteurs prédominants sur la variabilité spatio-temporelle de l'humidité du sol sont fortement dépendants de l'échelle observée. La Figure 2.8, tirée de [Peng et al., 2017], présente les principaux facteurs contrôlant les variations d'humidité du sol en fonction des échelles observées. Ainsi à l'échelle locale, les variations de texture de sol expliquent principalement les variations d'humidité d'un site à l'autre. C'est-à-dire que 2 parcelles, séparées d'une dizaine de mètres n'auront pas la même humidité principalement à cause des variations de textures de sol. Lorsque l'on passe à l'échelle d'un bassin versant, les variations sont contrôlées principalement par la topographie. Les pentes et les orientations modifient les écoulements, l'exposition aux rayonnements, etc... Et lorsque l'on passe à l'échelle régionale, ce sont les forçages atmosphériques qui expliquent les variations d'humidité du sol.

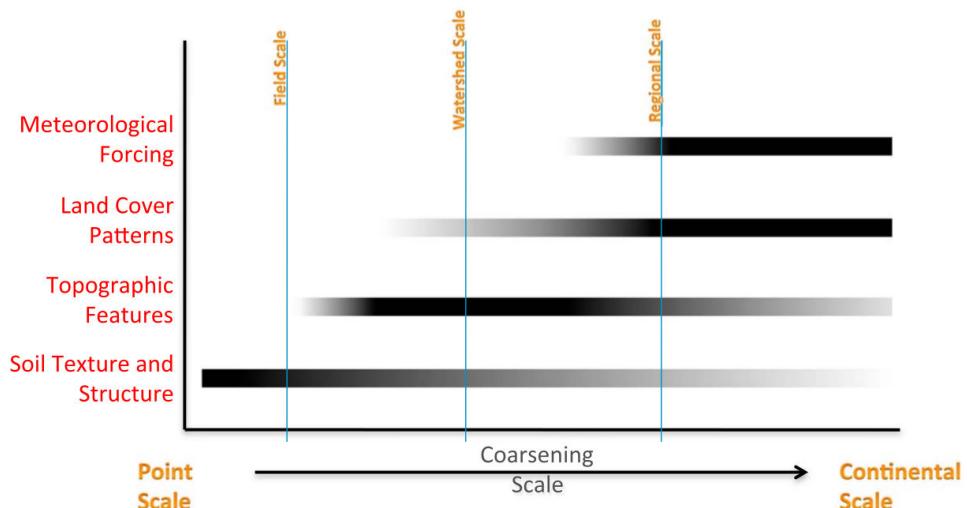


FIGURE 2.8 – Principaux facteurs contrôlant les variations spatiotemporelles de l'humidité du sol en fonction de l'échelle observée [Peng et al., 2017].

Les sondes d'humidité des sites du Bénin et du Niger sont donc utilisées ici afin d'étudier cette hétérogénéité pour la zone d'étude. Celles-ci sont disposées à plusieurs kilomètres les unes des autres (voir carte 2.2 et 2.5), la méthode employée est une intercomparaison "sonde-à-sonde" selon les scores de corrélation, RMSE débiaisé et biais pour les deux sites. Le résultat est résumé pour les neuf années de données à 5 cm, sur les matrices de la Figure 2.9. Le nom des sondes est défini de la sorte : les deux premières lettres correspondent aux deux premières lettres du site, puis la troisième lettre correspond à la position de la sonde dans le site, avec B pour Bas, M pour Moyen et H pour Haut.

- Site du Bénin

- a) La diagonale de corrélation à 1 correspond aux auto-corrélations entre les sondes. On remarque que globalement les sondes sont fortement corrélées entre elles ( $>0.8$ ), sauf les sondes situées en bas de pente (près des rivières). Sur ces points, il arrive que le sol se sature en eau pendant des périodes variant entre 1 et 10 jours après un événement pluvieux. La corrélation avec les autres sondes est en conséquence plus faible.

- b) En termes de ubRMSE, le résultat est similaire à a), c'est-à-dire globalement faible ( $<0.04 \text{ m}^3.\text{m}^{-3}$ ), il augmente pour les sondes situées en bas de pente.
  - c) Le biais quant à lui est assez variable, et ce même pour deux sondes du même site. Cela peut être dû soit à une différence de calibration entre les sondes, soit à une différence de texture de sol très prononcée ou encore à un mauvais contact entre une sonde et le sol.
- Site du Niger
    - d) Globalement la corrélation entre les sondes montre des variations consistantes entre les sondes sauf pour une des sondes de Tondikiboro.
    - e) Le ubRMSE est plus élevé pour les sondes de Wankama mais reste en dessous de  $0.02 \text{ m}^3.\text{m}^{-3}$  d'humidité.
    - f) Le biais est assez prononcé pour une des sondes de Banizoumbou (BZ1) et de Tondikiboro (TK1) mais reste assez faible globalement ( $<0.01 \text{ m}^3.\text{m}^{-3}$ ). Il est possible que l'épaisseur du sol évolue localement sous l'effet du vent et de l'érosion, et puisse avoir un effet sur le biais de certaines sondes.

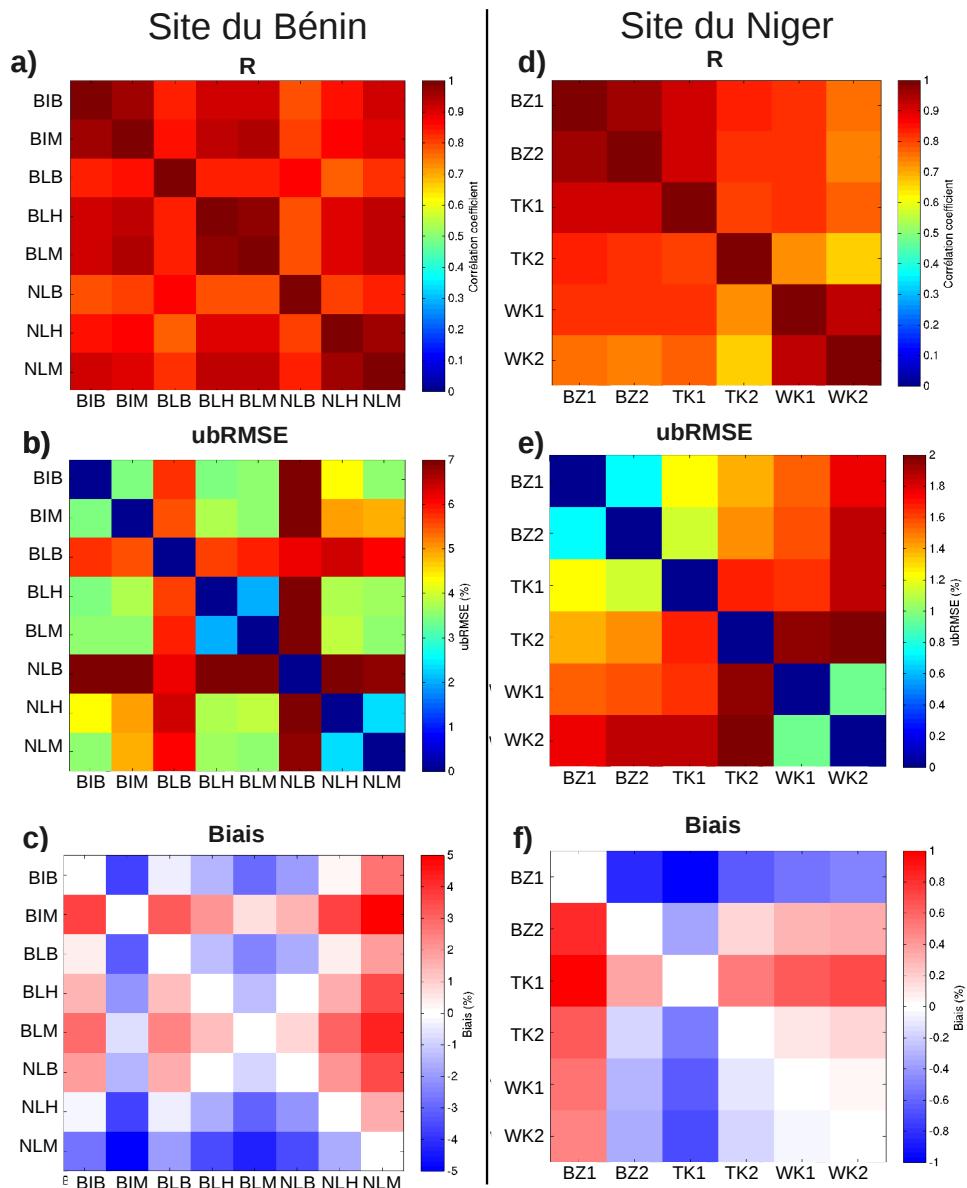


FIGURE 2.9 – Intercomparaison des scores des sondes d'humidité du sol à 5 cm pour les sites du Bénin (colonne de gauche) et du Niger (colonne de droite). La première ligne correspond aux corrélations entre les sondes, la seconde, au RMSE débiaisé, et la dernière au biais.

La question sous-jacente est : "quelle est la représentativité spatiale d'une sonde ?" Pour cela reprenons les intercomparaisons de sondes et représentons-les selon la distance qui les sépare :

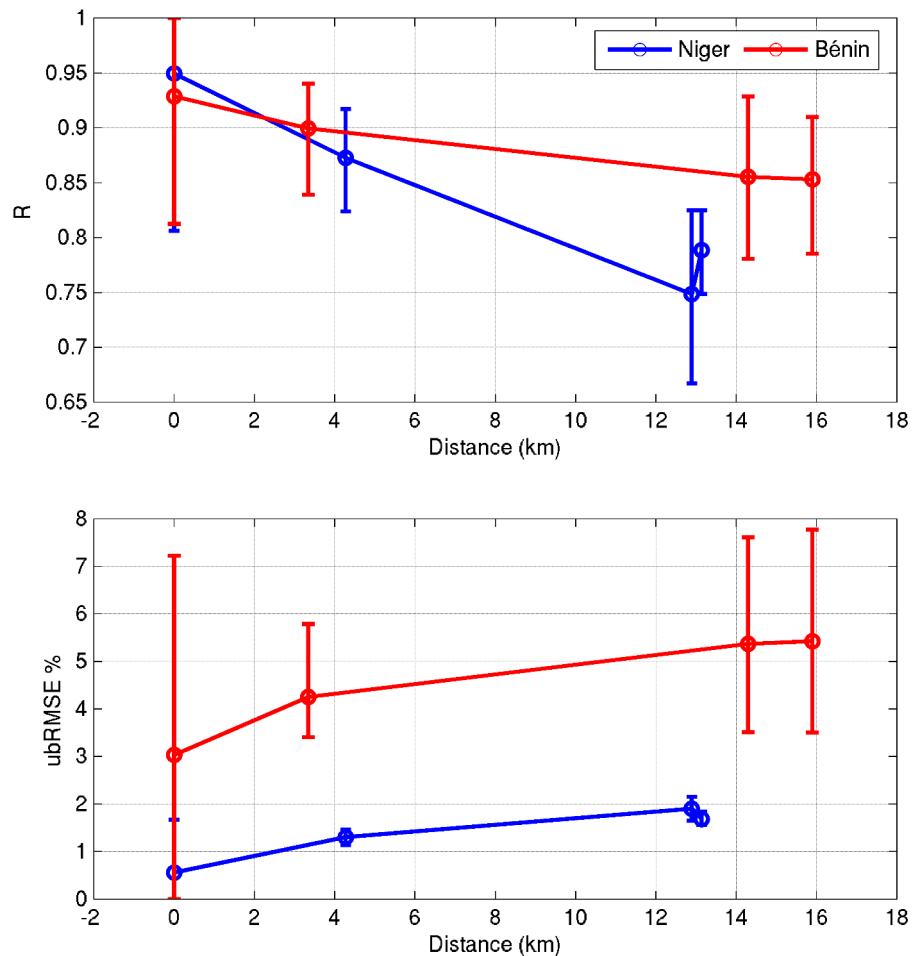


FIGURE 2.10 – Intercomparaison des scores des sondes d'humidité du sol à 5 cm pour les sites du Bénin et du Niger en fonction de leur distance d'éloignement.

La figure 2.10 représente ainsi la décroissance de score en fonction de la distance. On constate que la pente est assez différente entre le Niger (en bleu) et le Bénin (en rouge). La pente du Niger est de -0.02 points de corrélation par kilomètre de distance, alors qu'elle est de -0.004 points de R par km au Bénin.

Plusieurs hypothèses peuvent expliquer ces scores. D'une part, la texture du sol est relativement homogène respectivement dans les deux sites (voir cartes d'occupations 2.3 et 2.6). La texture plus sableuse au Niger qu'au Bénin peut expliquer les différences de propriété d'infiltration du sol entre les deux sites.

Une autre piste résiderait dans la dynamique des systèmes précipitant. Des systèmes moins fréquents et moins étendus au Niger qu'au Bénin pourraient expliquer ces différences de pente.

## 2.4 Télédétection spatiale : SMOS pour les mesures globales

Dans cette partie, les produits de télédétection spatiale sont présentés. Tout d'abord, la méthode d'estimation d'humidité du sol par SMOS (de la nature du rayonnement mesurée, jusqu'à l'inversion d'humidité du sol) est exposée, puis une évaluation des produits est ensuite effectuée.

### 2.4.1 Comment estimer l'humidité du sol depuis l'espace ?

SMOS est l'une des premières applications de la technique de radiométrie à synthèse d'ouverture, à deux dimensions, embarquée sur satellite pour l'observation de la Terre [Kerr et al., 2001]. La mesure radiométrique consiste à mesurer l'intensité d'une onde électromagnétique, dans différentes polarisations et une bande de fréquence définie. Le rayonnement mesuré est lié à la nature du matériau observé par la relation  $TB = e \cdot T$ ,  $TB$  étant la Température de Brillance (TB),  $e$  l'émissivité du matériau et  $T$  sa température. En mesurant la température de brillance, le radiomètre permet de retrouver des informations physiques concernant le matériau observé. Plus de détails sont disponibles dans [Annexe A : Théorie de la modélisation de l'émission naturelle dans les micro-ondes](#).

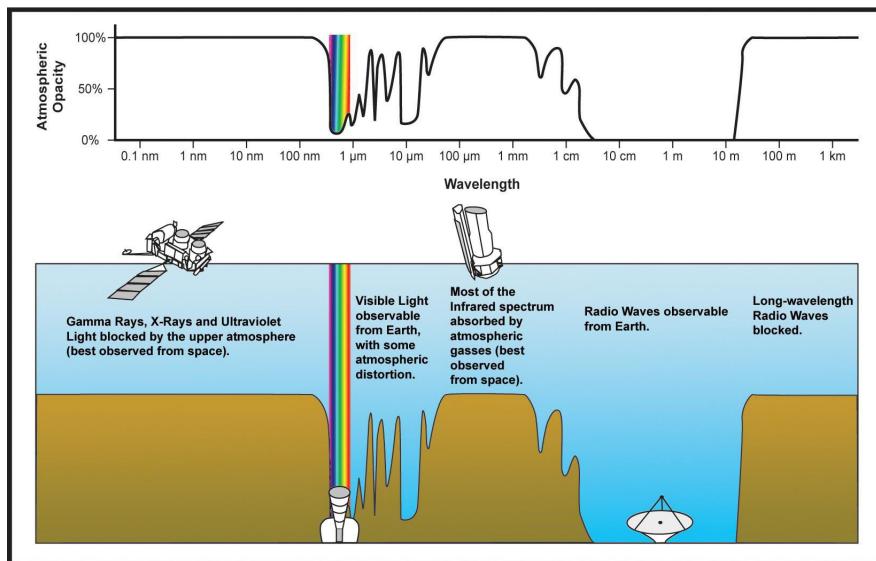


FIGURE 2.11 – Fenêtre de transparence spectrale de l'atmosphère : *Le marron sur la figure représente le taux d'absorption du rayonnement par l'atmosphère. C'est-à-dire que l'atmosphère n'absorbe quasiment pas les ondes radio mais absorbe les UV.* Source : [ipac.caltech.edu](http://ipac.caltech.edu)

Dans le cas de SMOS, la bande de fréquence choisie pour observer le sol est comprise dans la bande L à  $1,417 \text{ GHz} \pm 10 \text{ MHz} (\approx 21 \text{ cm})$ . Cette bande de fréquence est adaptée à la mesure de l'humidité des sols par radiométrie pour plusieurs raisons. L'une des raisons est la faible absorption atmosphérique des ondes radios (Figure 2.11), ce qui réduit la dégradation du signal par l'atmosphère. Une autre est que la bande de fréquence L est "protégée" [ANF, 2014] pour la télémesure et la radioastronomie amateur. Les ondes mesurées à cette fréquence ne proviennent donc "théoriquement" que du rayonnement naturellement émis par la Terre et l'espace. Par ailleurs, l'émission du sol dans cette bande de fréquence est fortement liée à la constante diélectrique du sol et donc à son état hydrique (FIGURE 2.12 et Figure A.7 en ANNEXE A).

Cependant, le rayonnement micro-onde est aussi sensible aux variations de températures de brillance émises par la végétation, ce qui rend la mesure d'humidité du sol difficile en cas de fort couvert végétal.

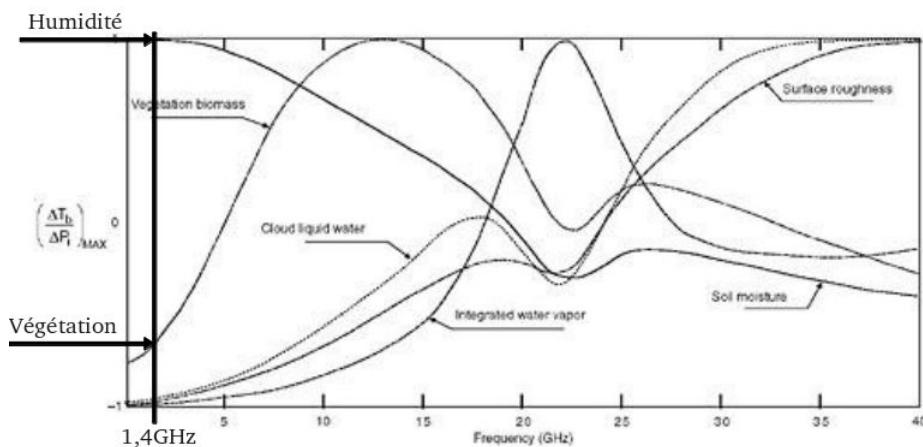


FIGURE 2.12 – Sensibilité du rayonnement à différents paramètres géophysiques : le marqueur vertical (barre noire) représente la fréquence de mesure de SMOS, et les flèches, l'importance de l'humidité et de la végétation à cette fréquence. Source : Kerr

L'instrument principal de SMOS est un radiomètre à synthèse d'ouverture. Ce dernier est composé de 69 antennes disposées sur 3 bras en Y, chaque antenne étant séparée de sa voisine d'une distance de  $0,89 \lambda$ . Ces antennes LICEF, pour LLight Cost Effective Front-end, sont des dispositifs composés d'antennes patchs circulaires dimensionnées pour la bande L. Basée sur le principe de l'interférométrie, cette technique permet de réduire considérablement la taille du capteur tout en gardant les mêmes résolutions angulaire et spatiale.

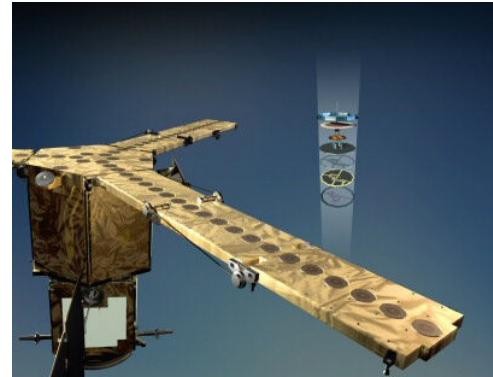


FIGURE 2.13 – Vue artistique de l'instrument MIRAS ESA

Lorsque SMOS fait une mesure, il effectue de multiples corrélations entre chacune de ses antennes. Ces corrélations permettent de créer des lobes d'antennes synthétiques et ainsi de reconstruire un champ de température de brillance à une résolution moyenne de 43 km (Figure 2.14) appelé "snapshot". Chaque point de ce "snapshot" est alors vu selon un angle d'incidence différent (FIGURE 2.15). En avançant sur son orbite, le satellite observe un nouveau "snapshot" différent du précédent. De cette manière, un point fixe au niveau du sol est vu sous différents angles d'incidence. L'aspect multi-angulaire de la mesure SMOS est une des caractéristiques innovantes de ce capteur. En effet, les antennes paraboliques classiques ne mesurent l'émission de la Terre que pour un seul angle d'incidence (par exemple la mission satellite SMAP mesure l'émission de la Terre en bande L seulement pour un angle de  $40^\circ$ ). L'aspect multi-angulaire de la mesure permet d'obtenir une signature telle que celle présentée sur la Figure 2.16 et d'utiliser cette information angulaire pour mieux quantifier la part du signal provenant de la surface végétale.

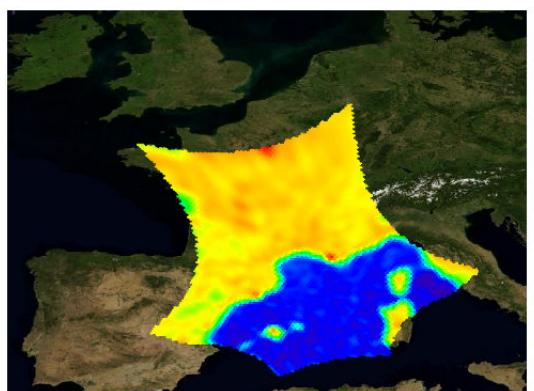


FIGURE 2.14 – "snapshot" du 22/06/13

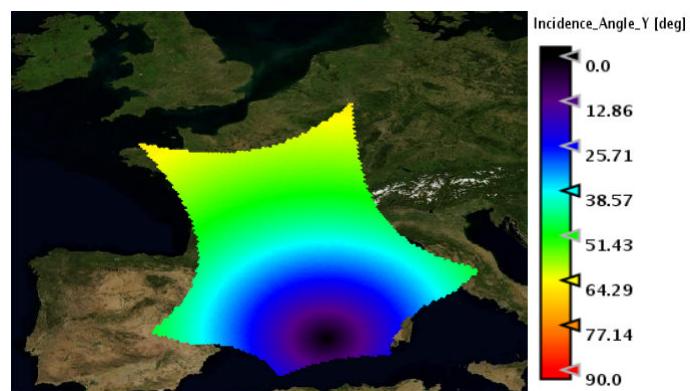
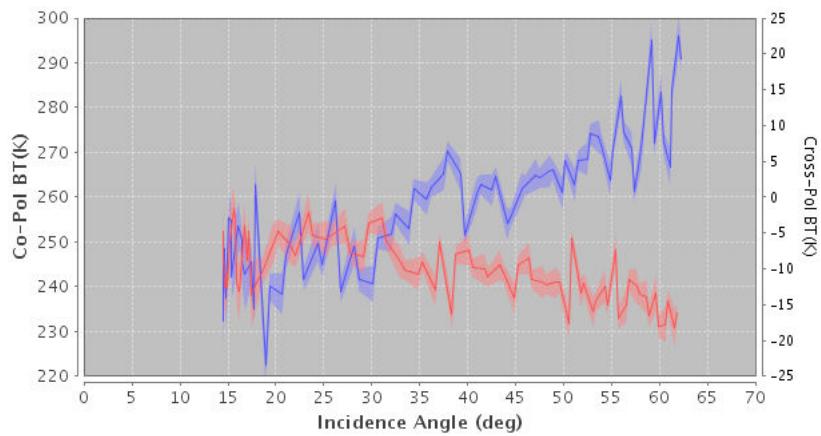


FIGURE 2.15 – Angles d'incidence

Pour un point sur la Terre, les mesures de températures de brillance sont représentées sous forme de profil angulaire. Sur la FIGURE 2.16 on peut ainsi observer l'évolution de l'intensité des températures de brillance dans le plan de l'antenne XY, en polarisations X (en rouge) et Y (en bleu), mesures au-dessus de Toulouse le 22/06/13.


 FIGURE 2.16 – Profils angulaires des TB au-dessus de Toulouse le 22/06/13 *TBY en bleu et TBX en rouge*

Pour extraire les paramètres d'humidité du sol à partir des températures de brillance, il faut se baser sur des modèles théoriques qui mettent en équations les caractéristiques du sol et de la végétation, en fonction des températures de brillance. Dans le cas de SMOS, des températures de brillance synthétiques sont obtenues à l'aide d'un modèle de transfert radiatif du sol : le L-band Microwave Emission of the Biosphere (L-MEB) [Wigneron et al., 2007]. Ce modèle permet de modéliser l'émission du sol et de la végétation dans la bande L. On appelle inversion de l'humidité le processus qui permet d'estimer l'humidité du sol à partir de valeurs de températures de brillance, pour une description détaillée voir [Annexe B : De la mesure de rayonnement à l'humidité du sol, description de l'inversion d'humidité](#).

À partir de cette chaîne de traitement un certain nombre de produits sont générés par l'ESA et le Centre Aval de Traitement des Données SMOS (CATDS) et sont disponibles sur internet :

- Level 0 : données brutes du satellite. Ces données numériques, reçues par paquets lors de la liaison de SMOS avec un segment terrestre, contiennent toutes les données d'observation et de télémétrie.
- Level 1 a : données de visibilités spatialisées dans le plan d'antenne (voir [Annexe B](#)).
- Level 1 b : résultat de la reconstruction des visibilités en températures de brillance au niveau du repère d'antenne.
- Level 1 c : températures de brillance sous forme de trace (snapshot tout le long de l'orbite).

- Level 2 : inversions des températures de brillance pour obtenir des cartes d'humidité des sols et de salinité des océans sur les mêmes traces (demi-orbes) que les L1c sur une grille à 15 km (grille ISEA4h9).
- Level 3 : carte d'humidité des sols et de salinité des océans, avec intégration temporelle, et donc angulaire, projetée sur une grille commune aux satellites d'observation de la Terre, l'EASEGrid, à 25 km.
- Level 4 : données transformées pour des applications opérationnelles de type hauteur d'eau, risque de sécheresse, inondation, etc.

C'est le produit Level 3 que l'on utilisera ici.

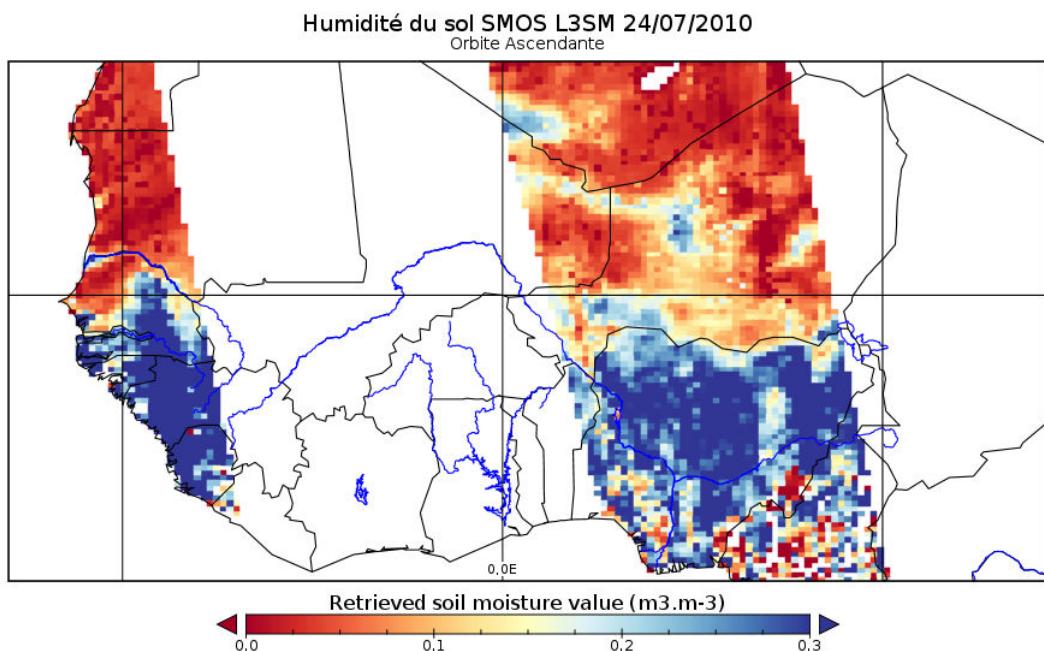


FIGURE 2.17 – Représentation de l'humidité du sol le long de la trace de l'orbite ascendante de SMOS pour le 24 juillet 2010, produit L3SM.

### Les indices de qualité

Dans le produit Level 3, celui utilisé ici, certains champs renseignent sur la qualité des estimations d'humidité effectuées. Parmi ces indices, il y a :

- DQX : cette valeur, en  $\text{m}^3.\text{m}^{-3}$ , est représentative de l'erreur radiométrique. C'est-à-dire la moyenne de l'écart des mesures de TB par rapport au profil simulé par le modèle de transfert radiatif, le L-MEB..
- CHI2 : cette valeur, de 0 à 1, est représentative de la qualité globale de l'inversion.
- RFIFraction : Indice permettant de représenter le nombre de mesures contaminées par les interférences RFI.

## 2.4.2 Évaluation de SMOS

Dans cette partie, les données d'humidité du sol SMOS sont comparées aux données *in-situ* pour les sites du Bénin et du Niger (le site du Mali s'étant arrêté en 2010 il n'est pas pris en compte dans cette étude, il l'est cependant dans [Louvet et al., 2015]).

### 2.4.2.1 SMOS au Bénin

La Figure 2.18 présente la surface du pixel SMOS (projétée sur la grille ESAEGGRID2) qui inclue les stations de mesure de l'humidité du sol sur le site du Bénin. On remarque que, par chance, le pixel contient l'ensemble des différentes stations. On peut aussi remarquer la présence de la ville de Djougou et de la forêt de Béléfoungou dans le pixel. La scène mesurée est donc principalement de la végétation basse, avec un faible fraction de zone urbaine et de forêt et peu de relief.

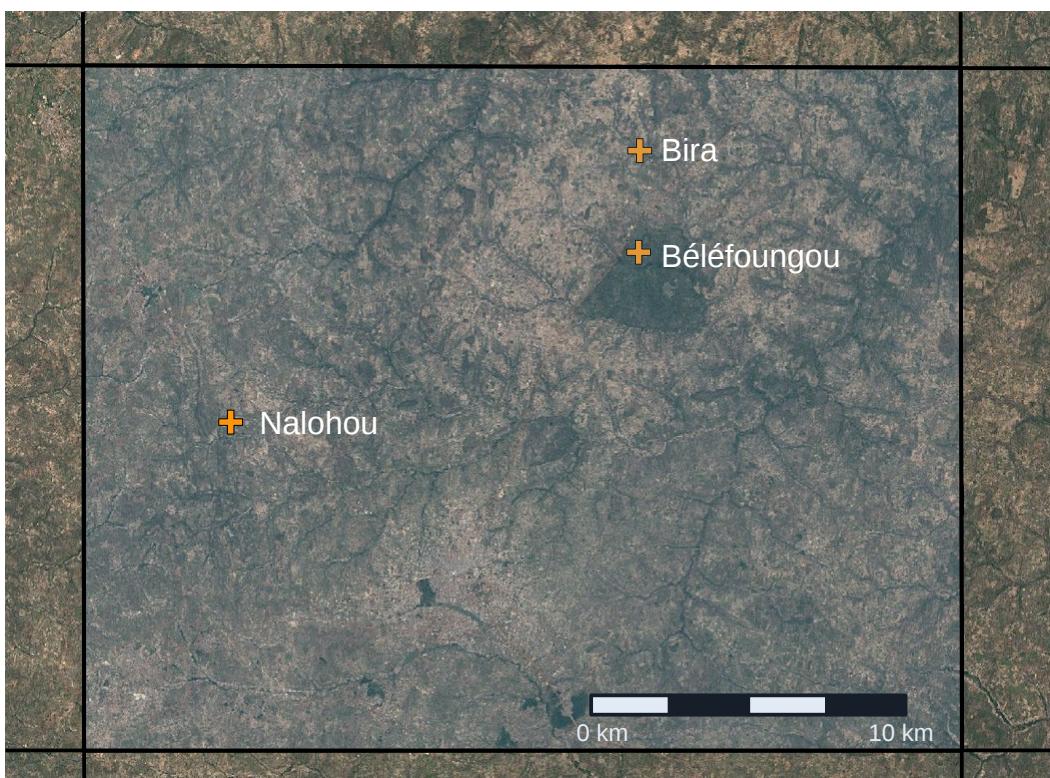


FIGURE 2.18 – Représentation du pixel SMOS (le carré bleu transparent) par rapport aux 3 sites AMMA-CATCH Bénin (fond de carte images Landsat Copernicus 17 novembre 2016).

Les séries temporelles en trait plein représentent l'évolution de l'humidité du sol de l'ensemble des huit sondes d'humidité dans le pixel SMOS (deux sondes à Bira, trois à Béléfoungou et trois à Nalohou). L'humidité du sol estimée par SMOS (L3SM) est représentée par des points rouges. On observe que la dynamique globale du produit est cohérente avec la monomodalité saison sèche/humide de cette région du Bénin. On remarque aussi que quelques données d'humidité SMOS sont largement au-dessus des mesures *in-situ* (probablement due à la différence de profondeur mesurée). Pendant la saison sèche on notera une dispersion assez forte des estimations SMOS ainsi qu'un biais positif.

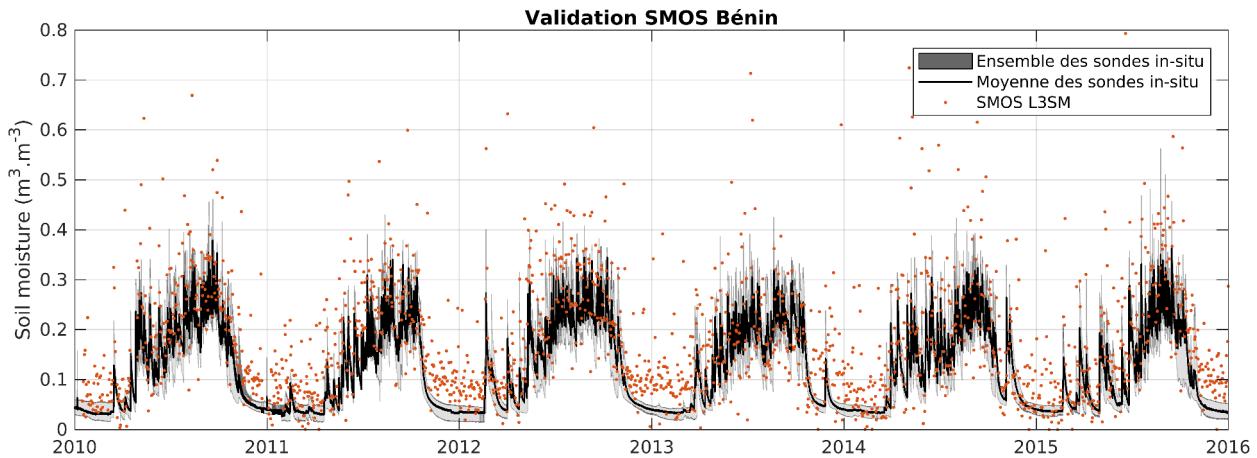


FIGURE 2.19 – Présentation des données d'humidité SMOS L3SM CATDS (points rouges) par rapport à l'humidité du sol 5 cm mesurées au Bénin (moyenne des sondes en noir et ensemble des sondes dans l'enveloppe grise).

La Figure 2.20 résume les scores de corrélation, de RMSE débiaisé et de biais pour chacune des sondes et pour chacune des six années de données SMOS. D'un point de vue de la corrélation (premier encadré), elle est en moyenne de  $R = 0.7$  pour les années 2010–2012 puis chute à  $R = 0.45$  en 2013,  $R = 0.55$  en 2014 puis revient à  $R = 0.7$  en 2015 (cette variation est due à un RFI qui sera présenté plus loin). En terme de ubRMSE, l'ensemble donne un ubRMSE de  $0.08 \text{ m}^3 \cdot \text{m}^{-3}$  pour 2010, 2011, 2012 et 2015. On retrouve cette dégradation de l'humidité du sol estimée par SMOS en 2013 et 2014 avec un ubRMSE de  $0.13$  et  $0.12 \text{ m}^3 \cdot \text{m}^{-3}$ . En terme de biais, la distribution est très hétérogène entre les sondes. On observe, par exemple un biais moyen de  $0.08 \text{ m}^3 \cdot \text{m}^{-3}$  pour la sonde Bira-Bas (BIB) alors qu'il est en moyenne de  $0.04 \text{ m}^3 \cdot \text{m}^{-3}$  pour la sonde placée à Bira-Moyen (BIM).

Lorsqu'on regarde la moyenne des sondes dans le pixel (barres rouges sur la Figure 2.19), on remarque qu'on se situe toujours parmi les meilleures corrélations et les plus faibles ubRMSE. Concernant le biais, il reste autour de  $0.06 \text{ m}^3 \cdot \text{m}^{-3}$ .

Ces résultats montrent que SMOS capte les variations d'humidité du sol en comparaison aux mesures *in-situ* au Bénin. Que l'hétérogénéité spatiale entre les sondes semble assez faible en termes de variations mais assez forte en termes de valeur absolue (forte dispersion des biais). Les différentes calibrations des sondes sont une des explications de ces variations de biais. Quant à la variabilité inter-annuelle, avec notamment cette chute des scores en 2013, elle est principalement due à la présence d'un RFI qui est apparu début Juin 2013 au nord du Ghana, voir 2.4.3.1.

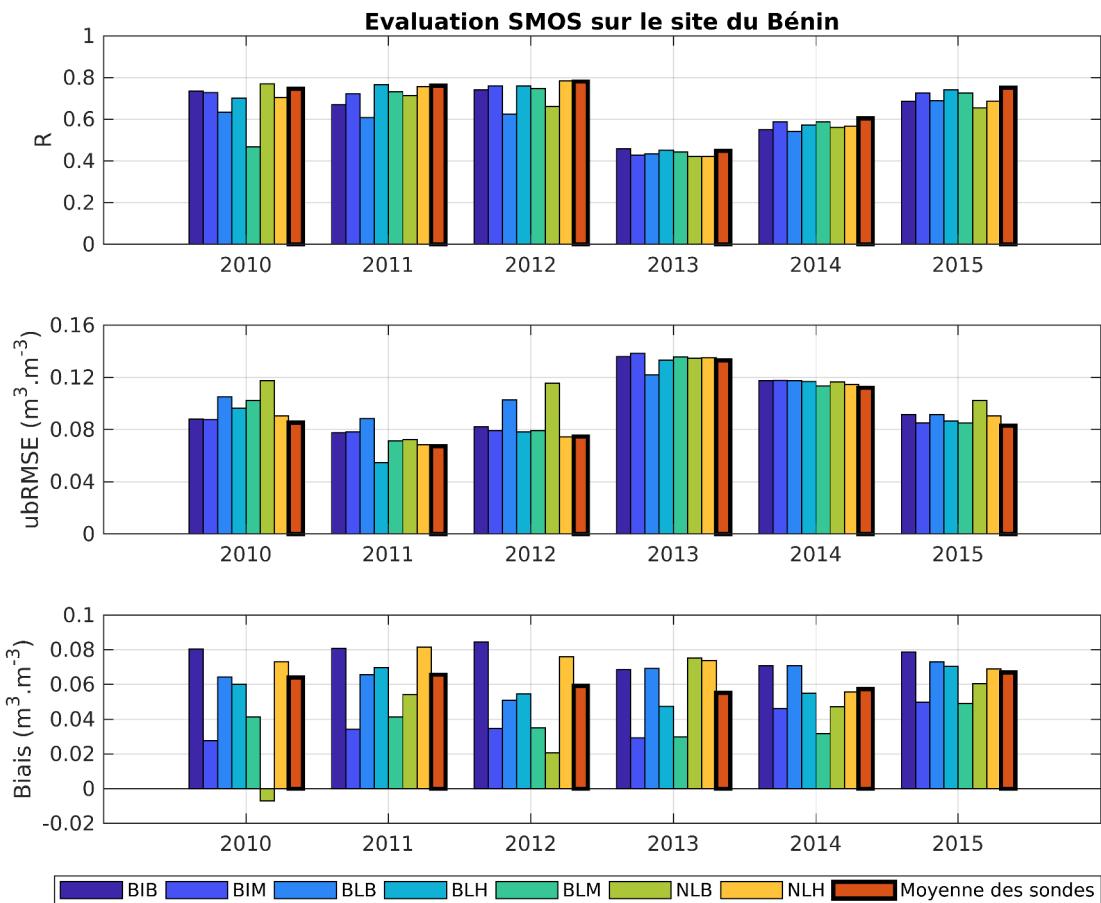


FIGURE 2.20 – Pour chacune des années et chacune des sondes du site du Bénin (représentée par des couleurs décrites dans la légende) : le premier bargraph représente le coefficient de corrélation annuel entre chacune des sondes et le produit d'humidité SMOS. Le second cadre représente le RMSE débiaisé et le dernier le biais des observations SMOS (SMOS-insitu).

#### 2.4.2.2 SMOS au Niger

La même démarche que pour le site du Bénin est appliquée à celle du Niger. La Figure 2.21 représente la position des sondes d'humidité du sol AMMA-CATCH par rapport au pixel SMOS (rectangle bleu transparent). On remarque que comme pour le Bénin, toutes les stations ici sont comprises dans le pixel. La scène est assez homogène, quelques cuirasses, un sol relativement sableux et peu de relief.

Les séries temporelles Figure 2.22 montrent des résultats similaires au cas du Bénin. En effet, SMOS représente bien la saison sèche et la saison des pluies, le tout avec un léger biais pendant la saison sèche. On retrouve là encore des données d'humidité SMOS qui sont bien au delà du maximum mesuré. Pour ce qui est des scores, la Figure 2.23 montre que la moyenne des corrélations est de 0.7 avec une baisse significative en 2014. Pour ce qui est du ubRMSE il est en dessous de  $0.05 \text{ m}^3 \cdot \text{m}^{-3}$  sauf pour 2013 et 2014. Quant au biais, il est toujours inférieur à  $0.02 \text{ m}^3 \cdot \text{m}^{-3}$ .

SMOS donne de bons résultats dans cette zone, comme montré dans [Louvet et al., 2015]. Le RMSE est faible et aux spécifications de SMOS ( $0.04 \text{ m}^3 \cdot \text{m}^{-3}$ ). Cependant on remarque, comme au Bénin, une dégradation des scores pour 2013/2014, voir 2.4.3.1.

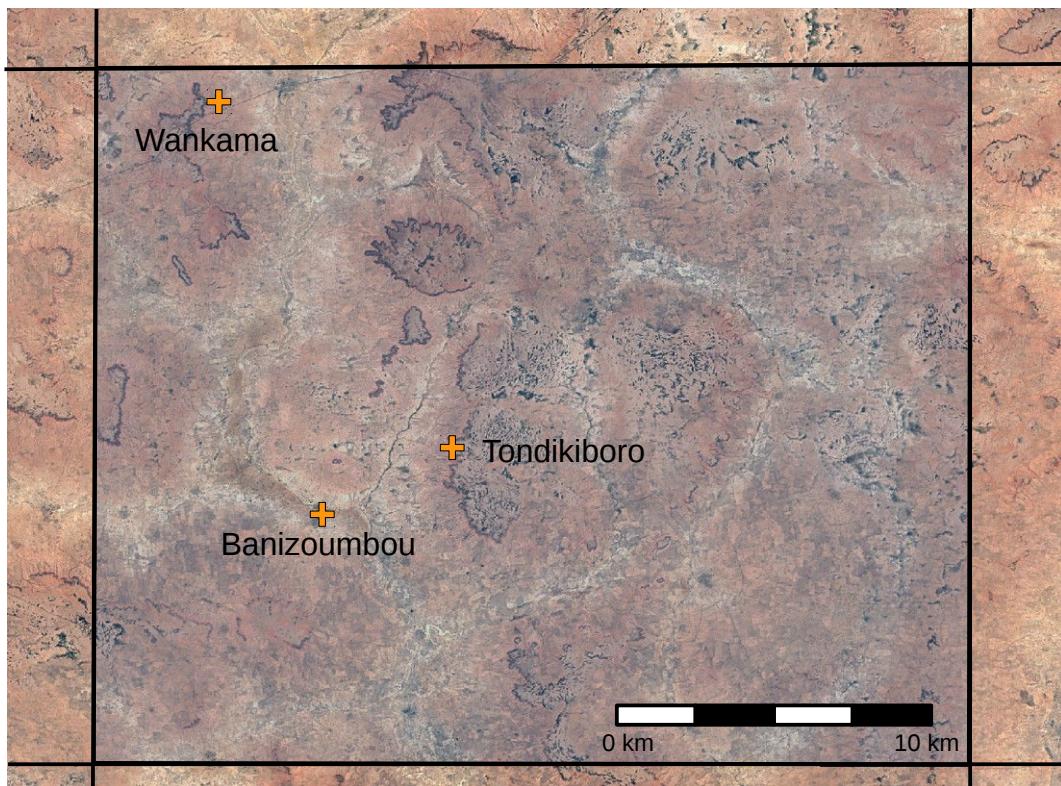


FIGURE 2.21 – Représentation du pixel SMOS (le carré transparent) par rapport aux trois stations du site AMMA-CATCH Niger (fond de cartes images Landsat Copernicus 17 novembre 2016).

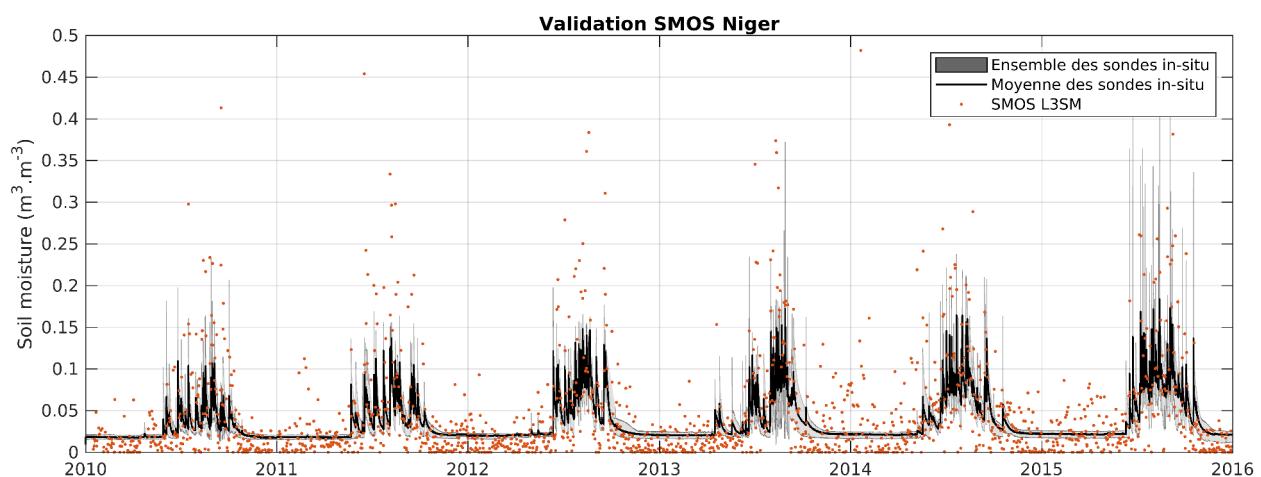


FIGURE 2.22 – Présentation des données d’humidité SMOS (points rouges) par rapport à l’humidité du sol 5 cm mesurée au Niger (moyenne des sondes en noir et ensemble des sondes dans l’enveloppe grise).

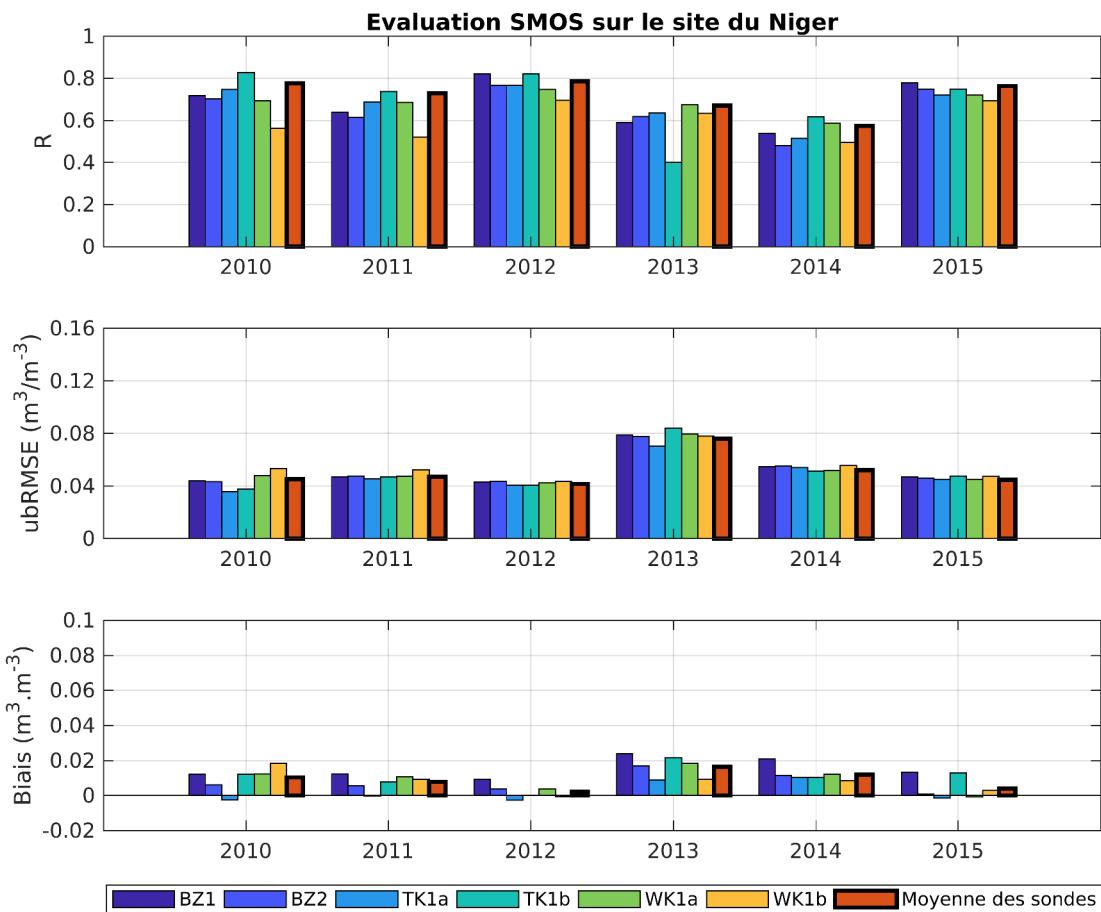


FIGURE 2.23 – Pour chacune des années et chacune des sondes du site du Niger (représentées par des couleurs décrites dans la légendes : le premier bargraph représente le coefficient de corrélation annuel entre chacune des sondes et le produit d'humidité SMOS. Le second cadre représente le RMSE débiaisé et le dernier le biais des observations SMOS (SMOS-insitu).

### 2.4.3 Limitations

#### 2.4.3.1 Impact des RFI

Bien que la bande de fréquence de SMOS soit protégée, il arrive que des émissions anthropiques réalisées de part et d'autre de la bande débordent légèrement, ce sont les Radio Frequency Interference (RFI).

Ces émissions anthropiques de fortes puissances comparées au signal émis naturellement viennent saturer la mesure très sensible. On peut observer par exemple les cartes des RFI Figure 2.24 du 23 mai et 6 juin 2013. Les tâches rouges correspondent aux RFI, on en retrouve principalement dans les zones de conflits militaires, au Moyen-Orient, à la frontière entre l'Inde et le Pakistan, mais aussi dans une bonne partie de la Chine, probablement dû aux émissions de télécommunications. Sur ces deux cartes on peut voir apparaître le RFI au nord du Ghana qui provoque la dégradation des données SMOS entre le 19 mai 2013 et le 23 mai 2015.

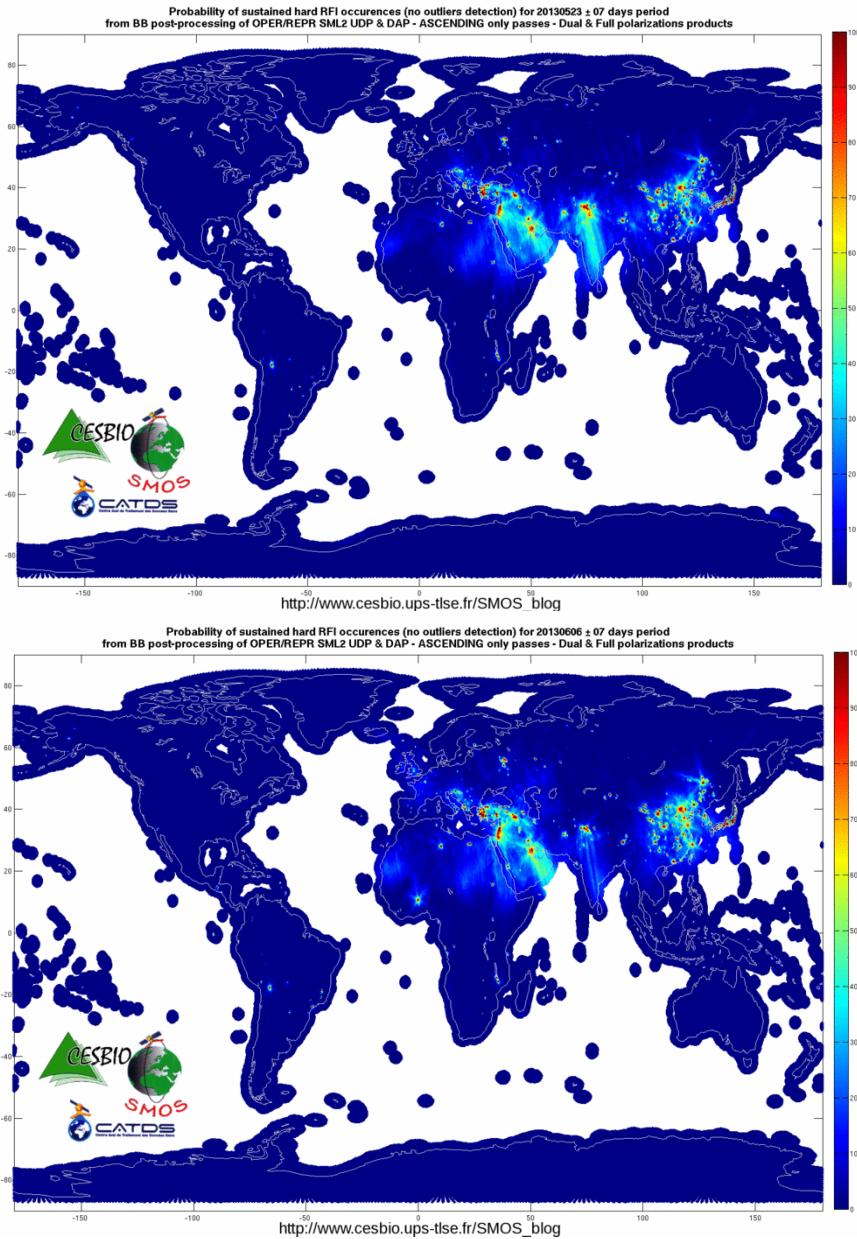


FIGURE 2.24 – La première carte est la probabilité de RFI au 23 mai 2013 et la seconde le 6 juin 2013, on peut voir apparaître le RFI au Nord du Ghana. Ce dernier perturbe les mesures SMOS au Bénin et plus légèrement au Niger.

L'impact de ces interférences sur les produits d'humidité est double. Tout d'abord la quantité de données où l'humidité est inversée est bien plus faible que la normale, comme le montre les cartes de nombre de vues annuelles Figure 2.25. Le nombre de valeurs d'humidité inversée au nord du Ghana passe de plus de 300 en 2012 à 0 en 2014 dans cette région. Deuxièmement, même si le nombre de vues ne semble pas trop impacté pour les deux sites du Niger et du Bénin, la qualité des observations SMOS est en revanche dégradée. Les indices de qualité résumés pour les pixels du Bénin Figure 2.26 et du Niger Figure 2.27 montrent bien l'influence du RFI sur la qualité d'inversion d'humidité (CHI2), ce qui explique la baisse des scores de validation de SMOS pour les années 2013/2014 remarquée dans les parties 2.4.2.1 et 2.4.2.2. On remarque que le CHI2 est très sensible à la présence de RFI, c'est explicable par le biais induit sur les  $TB_{SMOS}$  et donc impossible à modéliser par le  $TB_{Modele}$ .

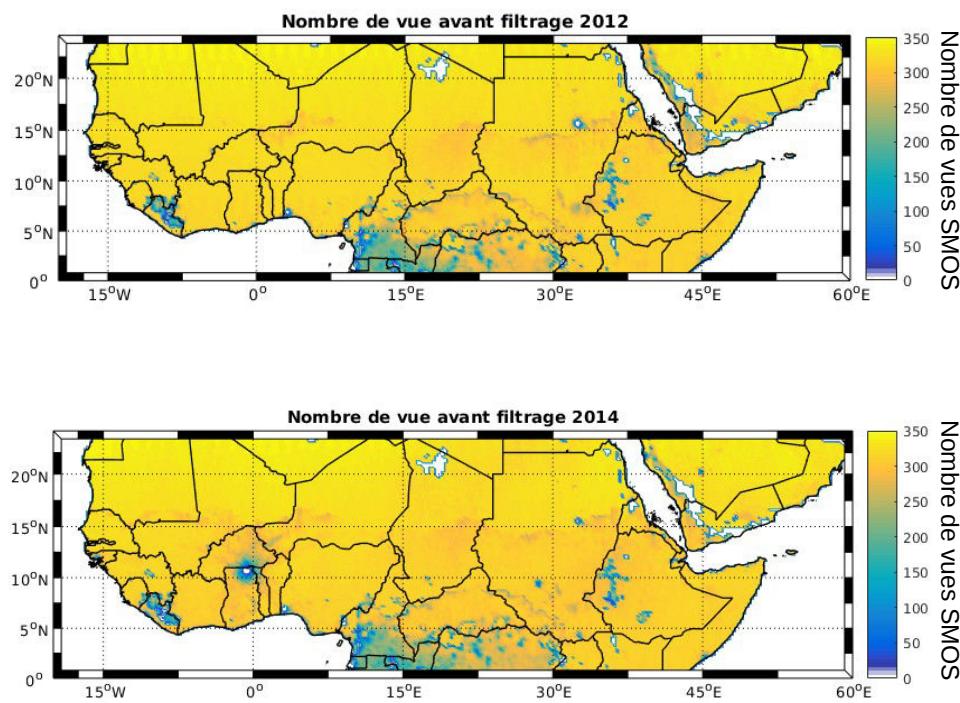


FIGURE 2.25 – Nombre d’inversions SMOS (orbite ascendante uniquement). On observe l’impact du RFI au Nord du Ghana pour les années 2012 et 2014.

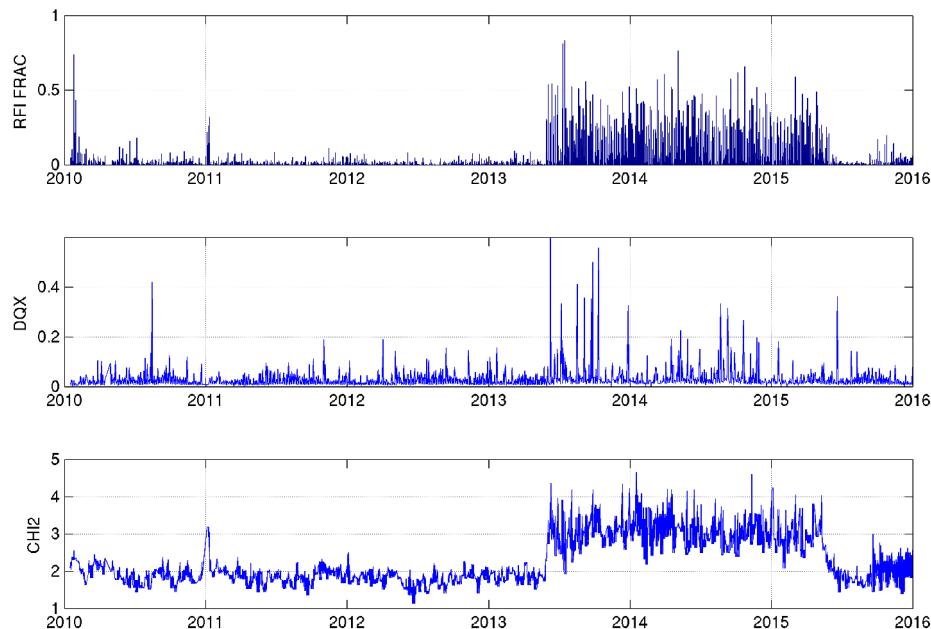


FIGURE 2.26 – Indices de qualité de SMOS pour le pixel du site du Bénin. Le premier graphique correspond au RFI Fraction, c'est-à-dire le taux de contamination du pixel par le RFI. Le second correspond au DQX (qualité de l’inversion) et le troisième est le CHI2 (Erreur absolue de  $TB_{SMOS} - TB_{MODEL}$  entre les deux profils angulaires).

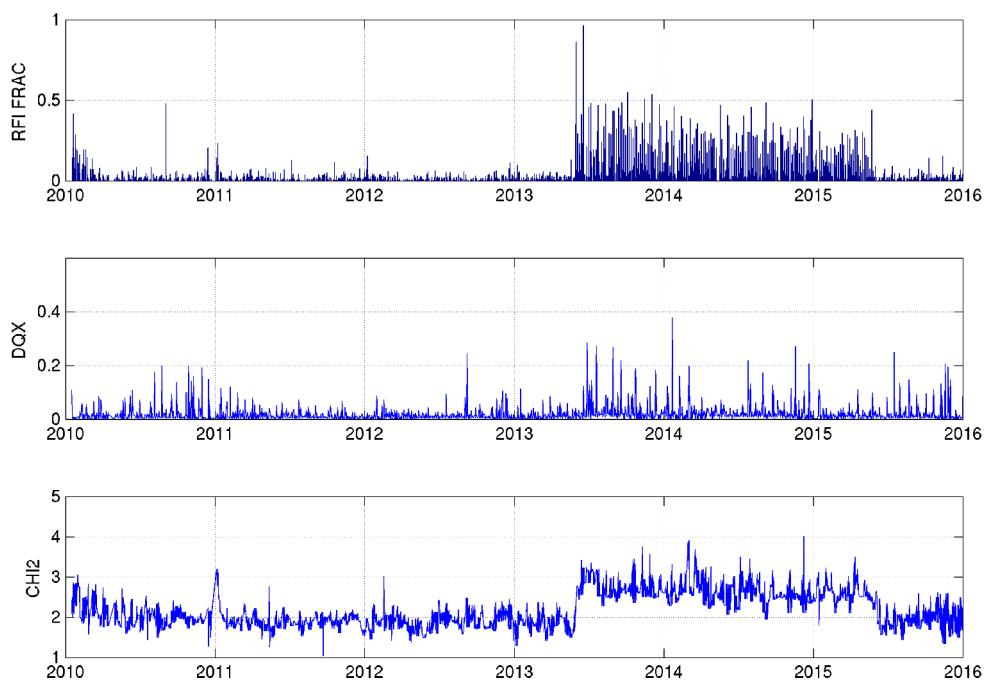


FIGURE 2.27 – Même figure que précédemment mais pour le site du Niger.

#### 2.4.3.2 Problématique du sous échantillonnage de SMOS

Une autre limite à SMOS pour représenter les variations d’humidité est sa fréquence de revisite. Les spécifications du satellite donnent une période de revisite de trois jours maximum. Afin d’analyser cette fréquence de revisite, la Figure 2.28 montre les proportions des durées entre deux observations de SMOS, pour le Bénin en a) et pour le Niger en b).

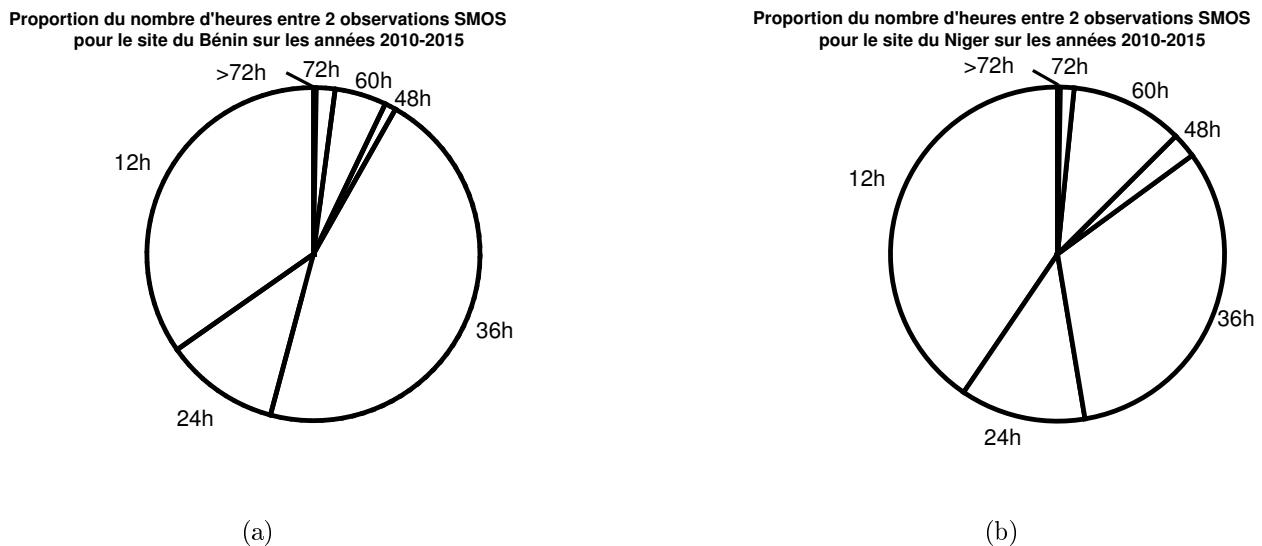


FIGURE 2.28 – Proportion du nombre d’heures entre deux observations SMOS pour les sites du Bénin en a) et du Niger en b) sur les années 2010–2015.

On remarque alors que dans 80–85% des cas la fréquence de revisite de SMOS sur le point est inférieure ou égale à 36 heures. Même si ces délais paraissent relativement longs comparé au temps d’infiltration et de ressuyage du sol lors d’événements de pluie successifs, certaines études, notamment [McColl et al., 2017], montrent qu’en moyenne et à l’échelle globale, la trace

d'humidité d'un événement pluvieux est encore visible trois jours après (soit 72 heures). Il est possible de représenter la problématique de l'échantillonnage pour les deux sites de l'étude. Les Figures 2.29 et 2.30, représentent respectivement les problématiques de sous-échantillonnage du satellite et la possibilité de représenter les variations lorsque le ressuyage dure de l'ordre d'une semaine. En effet, dans le premier cas, les "pics" d'humidité et la courbe de ressuyage sont difficilement captés par SMOS car les événements ont une fréquence trop élevée. Dans le second cas les événements sont séparés d'une semaine, ce qui rend la fréquence de revisite de SMOS compatible avec les "longs" événements de pluie.

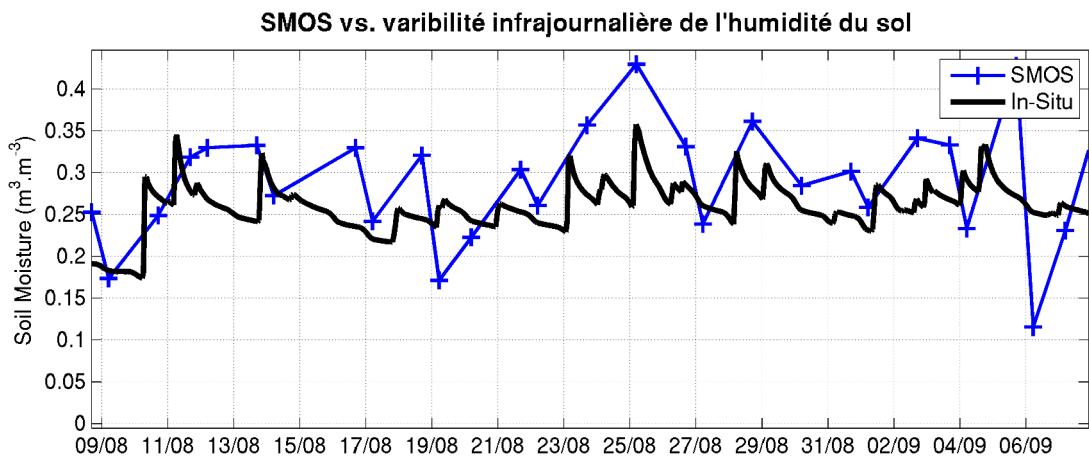


FIGURE 2.29 – Exemple de sous-échantillonnage de SMOS, les variabilités journalières ne sont pas captées par le satellite.

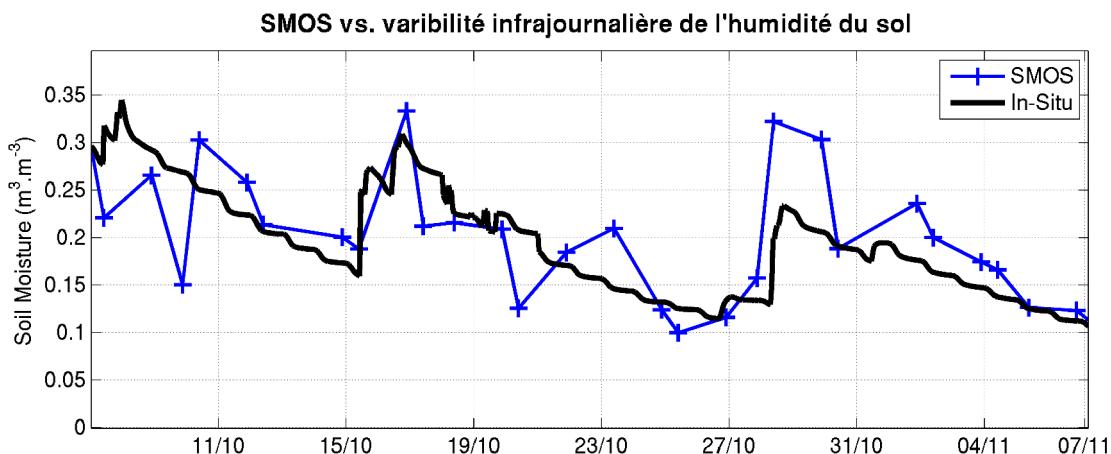


FIGURE 2.30 – Lors de gros événements de pluie avec plusieurs jours de ressuyage, la variabilité est bien captée par le satellite.

## 2.5 Modélisation numérique : SURFEX et API pour la simulation large échelle

Dans cette partie sont présentés deux modèles de surface de complexités différentes, un modèle à base physique, SURFEX, et un modèle empirique, API. Ce choix a pour but d'évaluer les différences de qualité des simulations de l'humidité par rapport au niveau de complexité et de ressource nécessaire (temps de calcul, champs de forçage, etc...). Nous verrons par la suite la sensibilité de ces modèles aux incertitudes de forçage.

### 2.5.1 Un modèle à base physique : SURFEX

Le modèle SURFEX, pour SURFace EXternalisée ([Martin et al., 2007] ; [Le Moigne, 2009]), est un schéma de surface global développé pour être couplé avec les modèles atmosphériques ARPEGE et AROME. SURFEX permet de modéliser les flux de surface en fonction des forçages atmosphériques. Il décrit les interactions surface-atmosphère pour 4 schémas physiques décrivant 4 environnements différents :

- Le sol et la végétation avec ISBA [Noilhan and Mahfouf, 1996].
- Les mers et les océans avec SEA [Gaspar et al., 1990]
- La ville avec TEB [Masson, 2000]
- Les lacs avec FLAKE [Salgado and Le Moigne, 2010]

Dans cette étude nous n'utiliserons que le schéma de description du sol et de la végétation, le module ISBA. ISBA, pour Interaction Surface Biosphère Atmosphère, est un modèle Surface Vegetation Atmosphere Transfer (SVAT) modélisant les flux décrit Figure 2.31 :

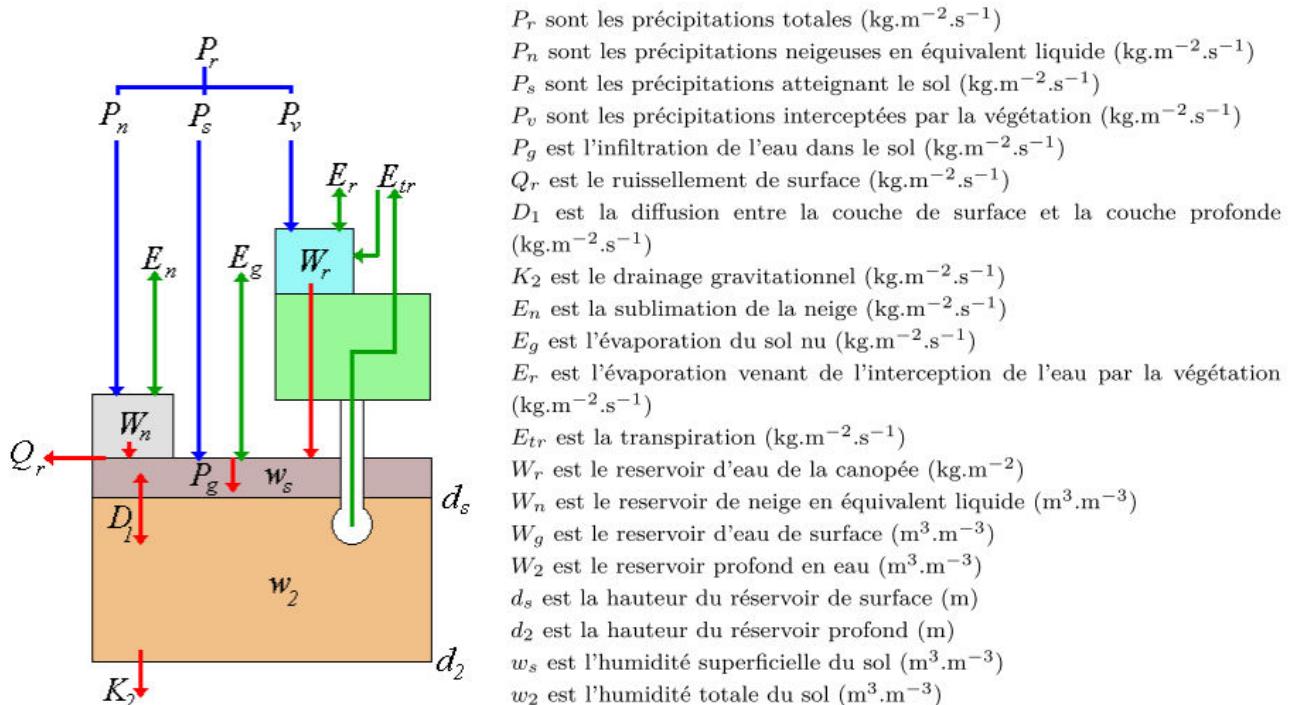


FIGURE 2.31 – Synoptique de la schématisation de surface dans ISBA (thèse de doctorat de Marie Parrens).

Dans la version d'ISBA décrite Figure 2.31, le sol a un comportement de type *bucket* Manabe, c'est-à-dire que la couche de sol se remplit uniquement lorsque les précipitations sont supérieures à l'évaporation (la diffusion de l'eau dans le sol n'étant pas prise en compte). Le comportement hydrologique quant à lui respecte le *force-restore* Deardorff. C'est-à-dire que le drainage dans la couche inférieure ne se fait que lorsque l'humidité est supérieure à la capacité de champ et le ruissellement apparaît lorsque l'humidité de la couche de surface dépasse la capacité d'infiltration du sol.

Cependant les deux couches de cette version ne sont pas adaptées à l'observation du front d'infiltration nécessaire pour aborder nos questions scientifiques. Pour mieux représenter le profil d'infiltration de l'eau dans le sol, nous utilisons la version diffusive de ce modèle, ISBA-DIF, qui prend mieux en compte la diffusion dans le sol, au travers l'équation de diffusion de Richards ([Richards, 1931]) :

$$\frac{\delta\theta}{\delta t} = \frac{\delta}{\delta z} [K(\theta) \left( \frac{\delta\psi}{\delta z} - 1 \right)] \quad (2.5)$$

Avec  $\theta$  l'humidité du sol (en  $m^3.m^{-3}$ ),  $t$  le temps (en s),  $z$  l'épaisseur de sol considérée (en m),  $K$  la conductivité hydraulique du sol en fonction de son humidité (en m/s) et  $\psi$  le potentiel matriciel (en m).

Ainsi l'eau est diffusée progressivement dans le sol tout au long de l'épaisseur  $z$  considérée. Concernant la paramétrisation de la colonne de sol (Fig 2.32), les paramètres sont issus des données fournies dans la base de données ECOCLIMAP ([Champeaux et al., 2005]). On utilisera donc ici les cartes de proportion sol/argile, présentées sur la Figure 2.33, issues de la base de données Food and Agriculture Organization of the United Nations (FAO) Soil Map of the World ([FAO, 1988], développées à partir de cartes et de plus de 1300 échantillons de sols. Ces deux cartes représentent respectivement les proportions de sable et d'argile dans la bande sahélienne. On remarque une forte proportion de sable dans le sud du Niger, proportion plus faible au Bénin. Ces informations sur la texture du sol sont utilisées pour calculer les propriétés hydrodynamiques des sols (à partir de fonction de pédotransfert). Cette base de données fournit des paramètres d'occupation du sol selon 272 classes différentes. Nous utiliserons ici une agrégation de ces classes selon les trois patchs : sol nu, végétation haute et végétation basse. Pour ce qui est de la distribution racinaire, issue d'ECOCLIMAP, le profil est représenté Figure 2.32. Pour plus d'informations sur la paramétrisation, voir [Annexe C : Listing SURFEX](#).

## 2.5. MODÉLISATION NUMÉRIQUE : SURFEX ET API POUR LA SIMULATION LARGE ÉCHELLE

---

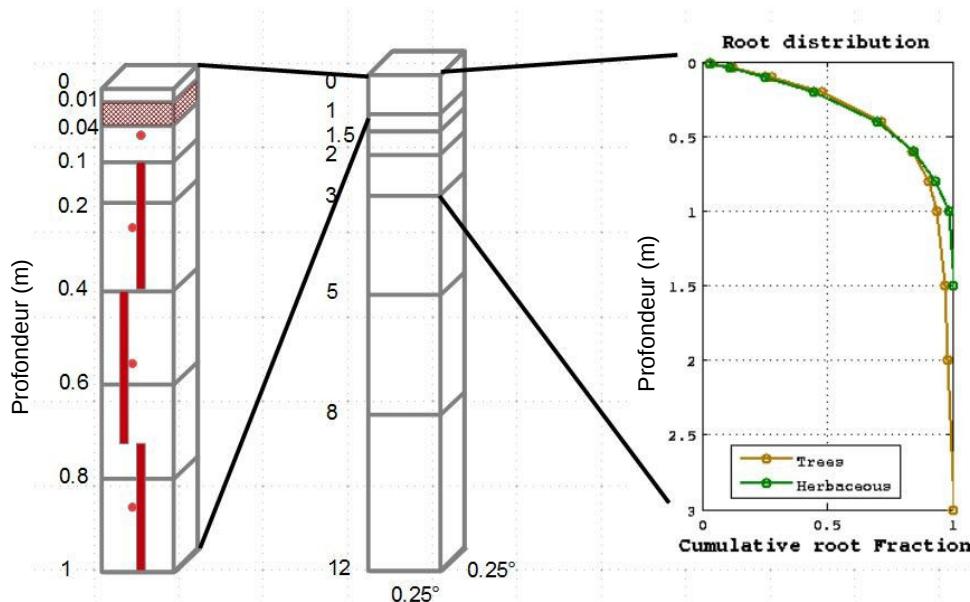


FIGURE 2.32 – La colonne de sol est divisée en 14 couches, avec les propriétés hydrodynamiques issues de la base de données ECOCLIMAP. La zone hachurée rouge (seconde couche) correspond à la zone compatible avec les données SMOS. Les points rouges correspondent aux profondeurs des sondes *in-situ* AMMA.

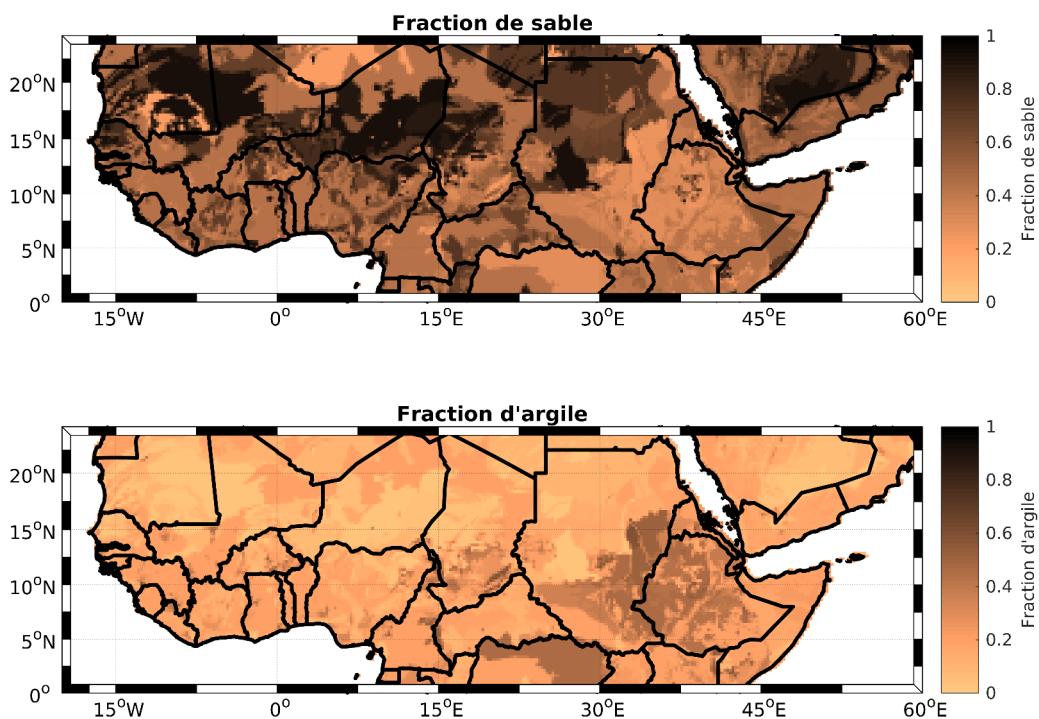


FIGURE 2.33 – Carte de texture de sol utilisée dans les simulations pour calculer les paramètres hydrodynamiques du sol.

### 2.5.2 Un modèle empirique : le modèle API

Le modèle API (Antecedent Precipitation Index) est un modèle simple liant les précipitations à un indice d'humidité du sol au travers une équation de transfert. Lors d'un événement pluvieux, l'humidité augmente puis diminue selon une exponentielle décroissante :

$$API_{(t)} = API_{(t-1)} \cdot e^{\frac{-\Delta t}{\tau}} + P_{(t)} \quad (2.6)$$

Avec  $P(t)$  la pluie cumulée (en mm) pendant la durée  $\Delta t$  (en heure), et  $\tau$  est le paramètre de ressuyage (en heure). Afin d'obtenir une estimation de l'humidité  $API_{(t)}$  en unité volumique, en  $\text{m}^3 \cdot \text{m}^{-3}$ , une modification de l'équation (2.6) est proposée dans [Pellarin et al., 2013] ; [Louvet et al., 2015], comme suit :

$$\theta_{(t)}^{5cm} = (\theta_{(t-1)}^{5cm} - \theta_{res}) \cdot e^{\frac{-\Delta t}{\tau}} + (\theta_{sat} - (\theta_{(t-1)}^{5cm} - \theta_{res})) \cdot (1 - e^{\frac{-P_{(t)}}{dsoil}}) + \theta_{res} \quad (2.7)$$

avec  $\theta_{sat}$  ( $\text{m}^3 \cdot \text{m}^{-3}$ ) la valeur de saturation du sol,  $d_{soil}$  l'épaisseur de sol considérée (en mm) et  $\theta_{res}$  ( $\text{m}^3 \cdot \text{m}^{-3}$ ) l'humidité résiduelle de surface. La relation est composée de trois termes qui s'additionnent. Le premier terme est analogue à l'équation (2.6) : lorsqu'il n'y pas de précipitation  $P(t)$ ,  $\theta_{(t)}^{5cm}$  décroît exponentiellement en fonction du temps jusqu'à atteindre l'humidité résiduelle  $\theta_{res}$  (intégration des processus d'infiltration et d'évaporation). Quand il y a un événement pluvieux, l'humidité  $\theta_{(t)}^{5cm}$  augmente proportionnellement à  $P(t)$  en fonction du degré de saturation du sol représenté par  $(\theta_{sat} - (\theta_{(t-1)}^{5cm} - \theta_{res}))$ . Remarquons aussi que la dynamique de  $\theta_{(t)}^{5cm}$  dépend également de l'épaisseur  $d_{soil}$ . Plus  $d_{soil}$  est grand, moins l'incrément sera grand. Observons la sensibilité du modèle à ces deux paramètres :

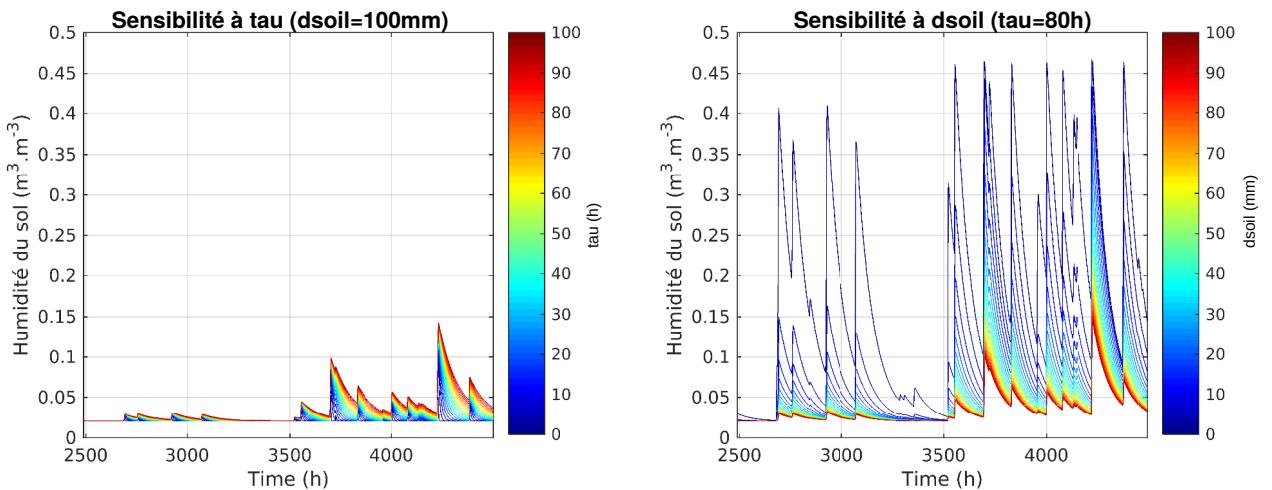


FIGURE 2.34 – Étude de sensibilité du modèle API aux paramètres  $\tau$  et  $d_{soil}$

Cependant, dans le cas des applications agricoles, l'information recherchée n'est pas uniquement l'humidité de surface, mais de l'humidité plus en profondeur. Pour cela un filtre passe-bas exponentiel est utilisé ([Wagner et al., 1999], [Albergel et al., 2008]). Ce filtre permet la propagation de  $\theta_{(t)}^{5cm}$  plus en profondeur, soit  $\theta_{(t)}^{Xcm}$ . Ce filtre est décrit comme suit :

$$\theta_{(t)}^{Xcm} = \theta_{(t-1)}^{Xcm} + K_{(t)} \cdot (\theta_{(t)}^{5cm} - \theta_{(t-1)}^{Xcm}) \quad (2.8)$$

avec le gain  $K_{(t)}$  :

$$K_{(t)} = \frac{K_{(t-1)}}{\frac{-\Delta t}{K_{(t-1)} + e^{\frac{T}{T}}}} \quad (2.9)$$

Le gain  $K_{(t)}$  dépend uniquement du temps et évolue entre 0 et 1 dans un intervalle  $T$  donné. Cet intervalle permet de modéliser le temps de propagation de l'humidité de la surface à une certaine profondeur x ([Ceballos et al., 2005]). Ainsi en modifiant T (en h), il est possible de modifier la profondeur simulée.

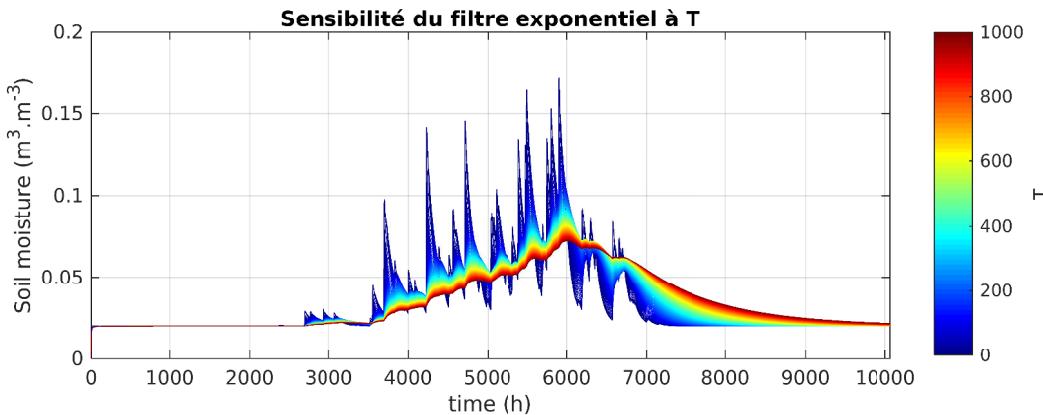


FIGURE 2.35 – Évolution de l'humidité simulée en fonction du paramètre T

### 2.5.3 Comparaison SURFEX/API

Les deux modèles présentés précédemment, SURFEX et API, permettent de modéliser l'humidité du sol en surface, et en profondeur. Dans cette partie, nous allons voir la qualité de leur simulation en les comparants aux mesures *in-situ*.

Pour cela le modèle SURFEX a été paramétré à partir d'ECOCLIMAP (voir le fichier de configuration [Annexe C : Listing SURFEX.](#)).

Le modèle API, quant à lui a été paramétré et calibré à partir des sondes *in-situ*. Pour cela, le modèle a été forcé par des champs de forçages atmosphériques MERRA (Modern-Era Retrospective analysis for Research and Applications) [Gelaro et al., 2017], voir [Annexe D Les forçages atmosphériques](#). Sur la base des coefficients précédents (le  $\tau$ ,  $d_{soil}$  et T) une calibration a été effectuée afin de maximiser les scores par rapport aux sondes des mesures *in-situ* sur la colonne de sol pour les sites du Bénin et du Niger. Sur le tableau 2.1 sont représentés les paramètres pour l'humidité de surface  $\theta_{(t)}^{5cm}$ . Sur la Figure 2.36, sont représentés les paramètres T utilisés dans cette étude pour le Niger et pour le Bénin.

TABLE 2.1 – Paramètres principaux des équations de l'API (2.5.2)

	Niger	Bénin
$\theta_{Sat}/\theta_{Res}$ (en $m^3 \cdot m^{-3}$ )	0.45/0.02	0.45/0.04
$\tau$ (en h)	90	120
$d_{soil}$ (en mm)	100	35

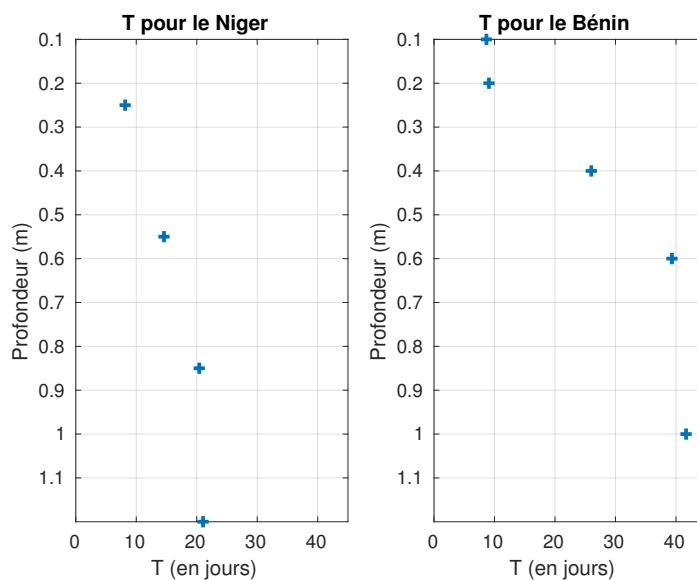


FIGURE 2.36 – Paramètres T du filtre exponentiel pour les sites du Niger du Bénin

Ainsi, à partir des 2 modèles présentés, et paramétrés, les simulations ont été effectuées pour les sites du Bénin et du Niger. Les séries temporelles sont représentées Figure 2.37 et 2.38 avec en bleu l'API et en rouge SURFEX plus la référence *in-situ* (en noir), pour les deux sites, à 5 cm. Les scores sont présentés Tableau 2.2. On peut alors observer que les deux modèles donnent de bons scores en corrélation, égaux ou supérieurs à 0.9. Le RMSE quant à lui est meilleur pour l'API que pour SURFEX dû au fort biais humide dans SURFEX.

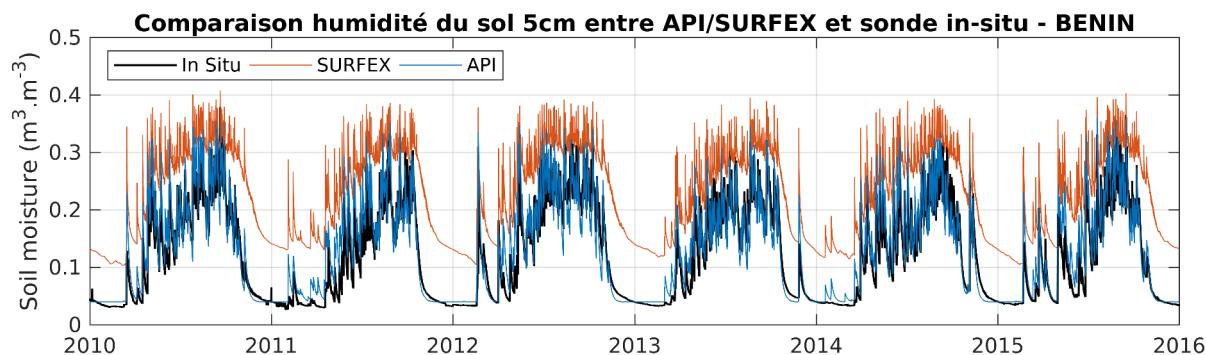


FIGURE 2.37 – Site du Bénin : Évaluation des modèles API (en bleu) et SURFEX (en rouge), forcés par des pluies *in-situ* et comparés aux mesures d'humidité AMMA-CATCH (en noir) à 5 cm de profondeur.

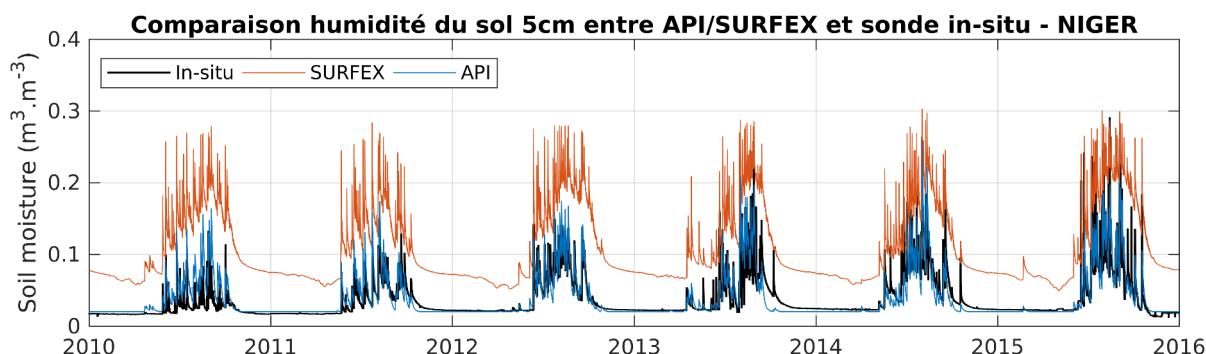


FIGURE 2.38 – Site du Niger : Évaluation des modèles API (en bleu) et SURFEX (en rouge), forcés par des pluies *in-situ* et comparés aux mesures d'humidité AMMA-CATCH (en noir) à 5 cm de profondeur.

## 2.5. MODÉLISATION NUMÉRIQUE : SURFEX ET API POUR LA SIMULATION LARGE ÉCHELLE

TABLE 2.2 – Évaluation des simulations à 5 cm.

		Niger		Bénin	
		API	SURFEX	API	SURFEX
5cm	R	0.939	0.90	0.934	0.93
	RMSE	0.0136	0.0805	0.032	0.11
	Biais	0.0029	0.073	0.011	0.107

Intéressons-nous maintenant à une analyse qualitative de l'ensemble de la colonne de sol. La Figure 2.39 compare les modèles aux mesures pour le site du Bénin et la Figure 2.40 pour le site du Niger. Puis, Figure 2.41, les simulations sont évaluées quantitativement.

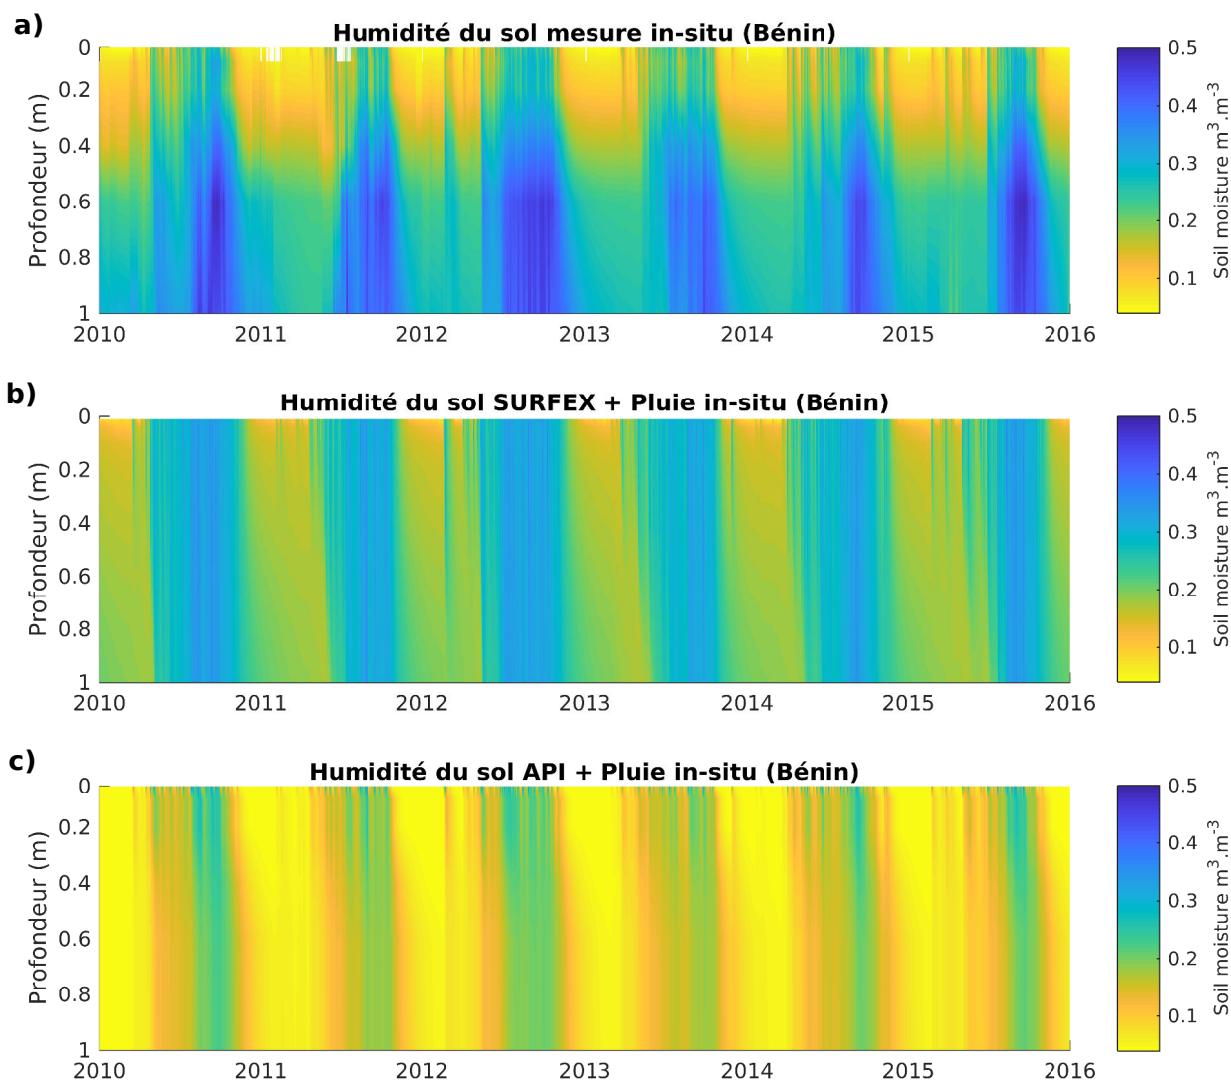


FIGURE 2.39 – Représentation de l'humidité du sol de 0 à 1 m à partir de a) mesures *in-situ* AMMA-CATCH Bénin, b) et c) modélisation SURFEX et API forcée par les précipitations des pluviomètres AMMA-CATCH.

La Figure 2.39 illustre la manière dont l'eau s'infiltra dans le premier mètre de sol, pour les années 2010–2015 pour le site du Bénin à partir de mesures *in-situ* en a) et de la modélisation en b) et c), pour SURFEX et API. Sur le premier graphique à partir des mesures *in-situ*, le a), on remarque que l'eau s'infiltra chaque année à plus d'un mètre de profondeur. On remarque

## 2.5. MODÉLISATION NUMÉRIQUE : SURFEX ET API POUR LA SIMULATION LARGE ÉCHELLE

aussi qu'à partir de 60 cm le sol semble plus humide pendant la saison sèche que dans les couches supérieures, créant ainsi un gradient d'humidité résiduel en profondeur. Pour la modélisation SURFEX (le second graphique), on observe une infiltration de l'eau dépassant les 1 m en pleine saison des pluies. On observe aussi la mauvaise modélisation de cette augmentation de l'humidité observée à partir de 60 cm de profondeur sur le profil a). Sur le profil c), on peut observer l'humidité du sol modélisée par le modèle API en surface puis propagée en profondeur au travers le filtre exponentiel. On remarque que pendant la saison sèche, l'humidité étant égale à l'humidité résiduelle dans l'API, un biais négatif important est créé au delà de 40 cm.

L'expérience a ensuite été réalisée pour le Niger. On observe Figure 2.40 en a) l'infiltration de l'eau à partir des sondes *in-situ*, en b) et c), simulée par SURFEX et l'API. A partir du graph a), on observe que certaines années comme 2010 ou 2011 l'eau ne semble pas s'infiltre beaucoup plus profondément que 1 m, on remarque aussi que les années 2012 et 2015 montrent une "pause" dans la saison des pluies. Sur le profil b), modélisé par SURFEX, on remarque alors une forte surestimation du taux d'humidité du sol. Sur le profil c), modélisé par l'API, la dynamique de l'humidité semble un peu faible par rapport aux mesures a).

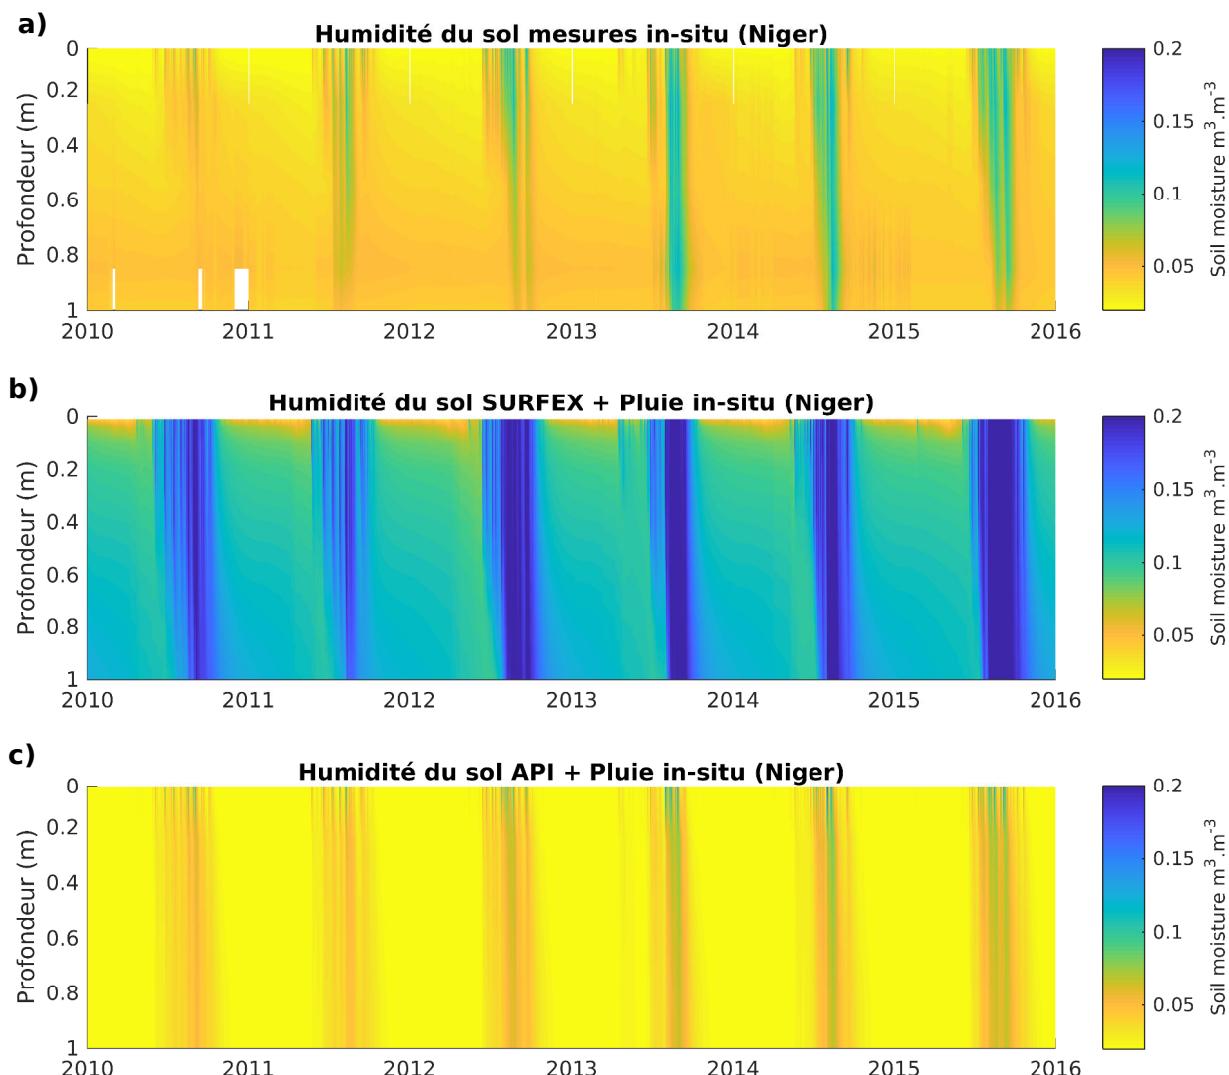


FIGURE 2.40 – Représentation de l'humidité du sol de 0 à 1 m à partir de a) mesures *in-situ* AMMA-CATCH Niger, b) et c) modélisation SURFEX et API forcée par les précipitations des pluviomètres AMMA-CATCH.

## 2.5. MODÉLISATION NUMÉRIQUE : SURFEX ET API POUR LA SIMULATION LARGE ÉCHELLE

Intéressons-nous maintenant aux scores sur les six années comparant toute la colonne de sol simulée avec les mesures *in-situ*, pour les deux sites et les deux modèles, Figure 2.41.

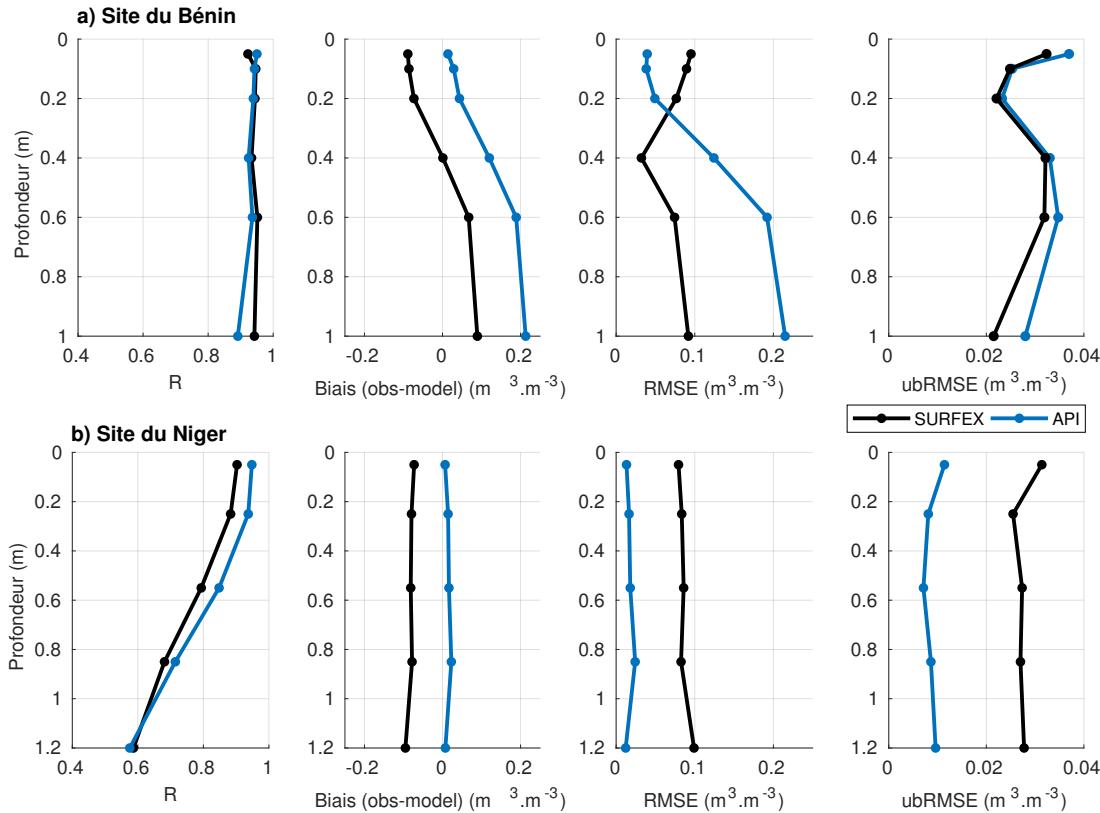


FIGURE 2.41 – Comparaison entre les mesures *in-situ* d’humidité du sol et les modélisations issues du modèle SURFEX, en noir et API en bleu, forcées avec les pluies *in-situ*, pour le Bénin (en haut) et pour le Niger (en bas).

Pour le site du Bénin, les scores de corrélation sont très bons, autour de  $R = 0.9$ , pour les deux modèles à toutes les profondeurs. Le biais, quant à lui, montre que SURFEX surestime en moyenne l’humidité jusqu’à 40 cm puis la sous-estime jusqu’à  $0.1 \text{ m}^3 \cdot \text{m}^{-3}$  à 1 m. Pour l’API, le biais est quasiment nul en surface, puis le modèle sous-estime l’humidité de manière croissante avec la profondeur, jusqu’à  $0.2 \text{ m}^3 \cdot \text{m}^{-3}$ . Cela est principalement causé par la nature du filtre exponentiel car il propage l’intégralité de l’eau en profondeur. Le RMSE est d’environ  $0.1 \text{ m}^3 \cdot \text{m}^{-3}$  en surface pour SURFEX, puis décroît jusqu’à 40 cm, là où le biais est nul, et ré-augmente car le biais augmente. Pour l’API le RMSE se dégrade car le biais augmente tout le long de la colonne. En analysant le RMSE débiaisé, ubRMSE, on observe un comportement relativement similaire pour les deux modèles.

Sur le site du Niger, les corrélations décroissent avec la profondeur pour les deux modèles. Pour le biais, SURFEX souffre d’une surestimation de l’humidité tout le long de la colonne alors que l’API a quasiment un biais nul. Pour le RMSE, il est très bon pour l’API et autour de  $0.1 \text{ m}^3 \cdot \text{m}^{-3}$  pour SURFEX. D’un point de vue du ubRMSE, il est de  $0.01 \text{ m}^3 \cdot \text{m}^{-3}$  pour l’API et autour de  $0.03 \text{ m}^3 \cdot \text{m}^{-3}$  pour SURFEX.

Ainsi, malgré leurs niveaux de complexité très différents, API et SURFEX donnent des résultats comparables et de bonne qualité pour ce qui est de représenter l’humidité dans les 50 premiers centimètres de profondeur de sol.

#### 2.5.4 Impact des incertitudes des précipitations sur les simulations d'humidité

Le point précédent a montré la qualité des simulations lorsque le forçage des pluies utilisées est issu de pluviomètres (mesures de pluie *in-situ*). Cependant, comme le montre la Figure 2.42, il est difficile de représenter la pluie spatialement au vu de la densité du réseau de pluviomètres. De plus, l'évolution temporelle du réseau a diminué de moitié en une vingtaine d'années, en passant de 725 pluviomètres en 1985 à 232 en 2004 [Ali and Lebel, 2009].

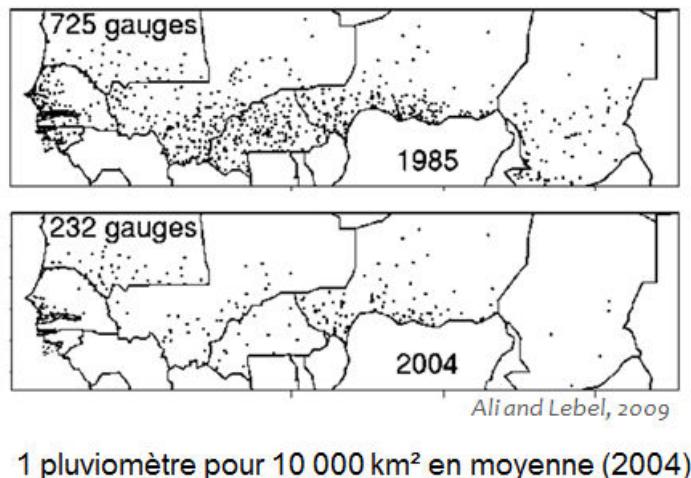


FIGURE 2.42 – Densité du réseau de pluviomètres en 1985 et 2014.

Une solution réside dans l'utilisation de produits de précipitation issus d'observations satellitaires. En effet, à partir de mesures infrarouges et/ou du contenu en eau de l'atmosphère avec des mesures dans les micro-ondes, il est possible d'obtenir des estimations sur les précipitations. Cependant, ces mesures sont soumises à de nombreuses sources d'incertitudes, parmi lesquelles les problèmes de remplissage du faisceau [Kummerow et al., 1998], d'incertitude sur l'échantillonnage [Steiner et al., 2003] ou encore d'estimation de la phase neige/glace [Bennartz and Petty, 2001]. Dans [Kidd and Levizzani, 2011], une revue bibliographique sur les progrès des algorithmes de précipitation par satellite est réalisée. Les auteurs montrent que les produits satellites ont atteint un bon niveau de maturité au cours des dernières années mais que les applications en hydrologie ou en agronomie sont encore limitées (notamment pour des problématiques de précision et de résolutions spatiale et temporelle).

Les produits couramment utilisés tel que CMORPH, TRMM ou encore PERSIANN, ont une résolution temporelle de 3 h et une résolution spatiale de 0.25°. Délivrés par différents organismes ils sont pratiquement tous disponibles en deux versions. Une version dite *real-time* (ou *Raw*), c'est-à-dire disponible avec un délai de quelques heures. Cette version est connue comme étant d'assez bonne qualité sur la temporalité des événements pluvieux (occurrence), mais mauvaise sur leurs intensités. Cela a des conséquences sur les applications, comme par exemple la modélisation hydrologique [Gosset et al., 2013]. Une seconde version est donc produite, dite *adjusted*, qui est corrigée à l'échelle mensuelle par les données *in-situ*. Elle est donc de meilleure qualité mais est délivrée avec un certain délai (~2 mois). Ce délai rend difficile leurs utilisations pour des applications opérationnelles nécessitant des informations en temps réel.

## 2.5. MODÉLISATION NUMÉRIQUE : SURFEX ET API POUR LA SIMULATION LARGE ÉCHELLE

Dans cette étude trois produits de pluie différents sont utilisés : 1) le produit Climate prediction center MORPHing method (CMORPH) [Joyce et al., 2004] (dans sa version ajustée CMORPHADJ et temps-réel CMORPHRAW), 2) le Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks (PERSIANN) [Sorooshian et al., 2000] (unique-ment dans sa version temps-réel car la version ajustée n'était pas disponible au moment de ces travaux) et 3) le produit Tropical Rainfall Measuring Mission (TRMM) [Huffman et al., 2010] (dans sa version ajustée TRMMADJ et temps-réel TRMMRAW). Ces produits permettent de représenter spatialement les précipitations dans les 3 dernières heures à une résolution de 0.25°. Dans un premier temps intéressons-nous à l'évaluation de ces trois produits sur nos deux sites, du Bénin et du Niger, à partir des pluviomètres AMMA-CATCH.

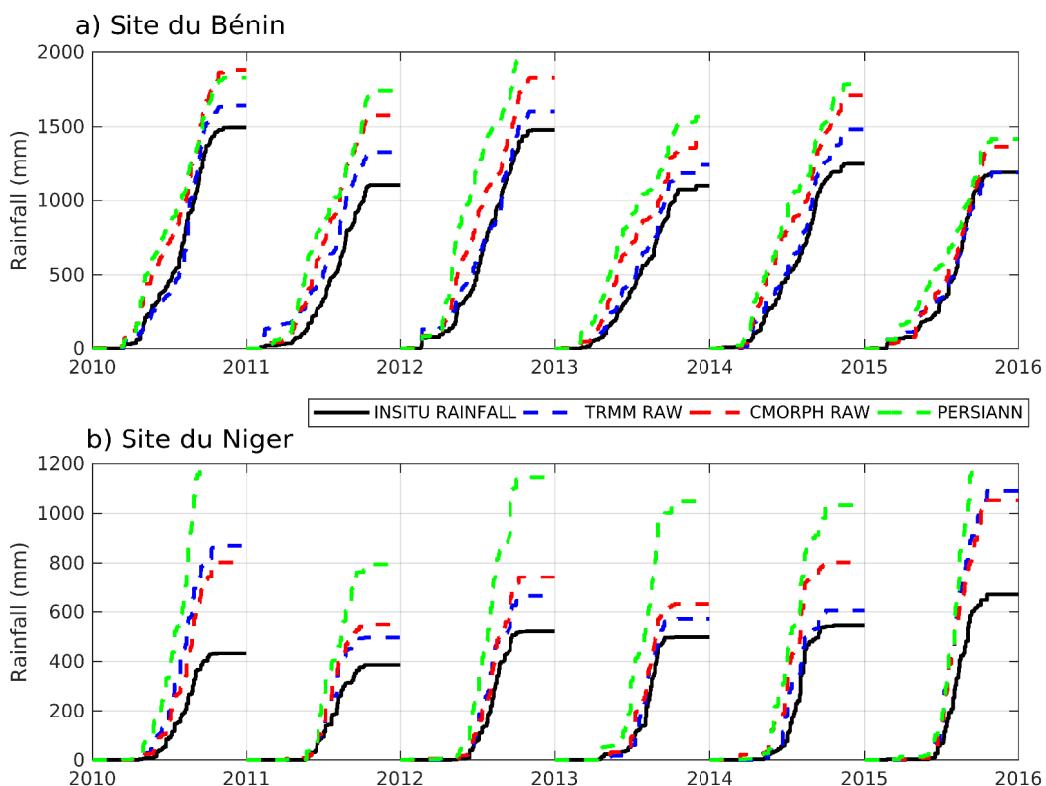


FIGURE 2.43 – Les produits de pluies satellites *temps-réel* sont présentées ici sous la forme de cumuls annuels. Ils sont comparés aux mesures *in-situ* (en noir), pour le Bénin en a) et le Niger en b).

Sur la Figure 2.43 sont représentés les cumuls annuels des produits de précipitations issues des pluviomètres AMMA-CATCH en noir et des produits de précipitations satellites dans leurs version *temps-réel*, avec TRMMRAW en bleu pointillé, CMORPHRAW en rouge pointillé et PERSIANNRAW en vert pointillé. On remarque alors tout de suite une forte surestimation des précipitations. Il existe une version de ces produits dit "ajustée", qui comprend une correction à partir de pluviomètres. Cependant un délai de quelques mois est nécessaire avant leurs distributions, ce qui est un véritable frein aux applications opérationnelles. Analysons la qualité de ces données Figure 2.44.

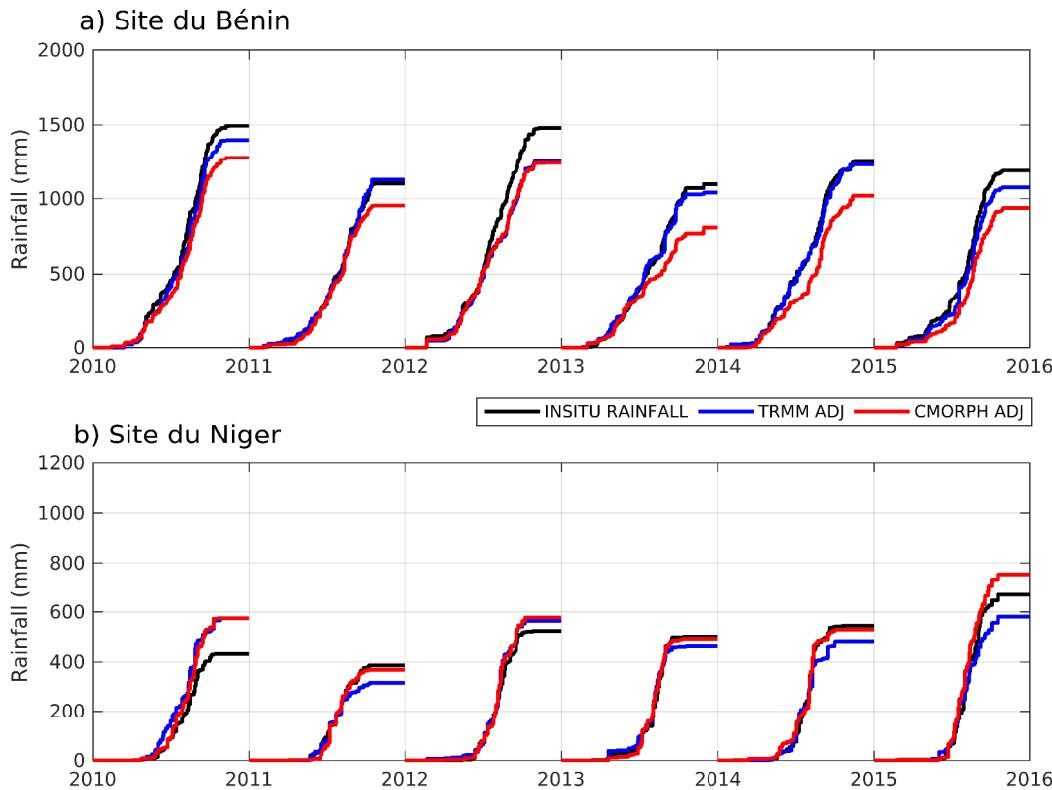


FIGURE 2.44 – Les produits de pluies satellites *ajustées* sont présentés ici sous la forme de cumuls annuels. Ils sont comparés aux mesures *in-situ* (en noir), pour le Bénin en a) et le Niger en b).

Sur la Figure 2.44 sont représentés les cumuls annuels pour les produits de précipitations issus des pluviomètres AMMA-CATCH en noir, et issus des produits satellitaires ajustés TRRMADJ et CMORPHADJ, en rouge et en bleu. On remarque que les 2 produits satellites sont différents, avec des courbes de cumuls différentes pour chaque année. La qualité des estimations semble assez variable d'une année à l'autre et d'un produit à l'autre. Ainsi par exemple en 2014 sur le site du Bénin, le produit TRMMADJ suit parfaitement le cumul des précipitations *in-situ* alors que le produit CMORPHADJ semble sous estimer certains événements. Remarquons que la situation inverse est aussi présente, sur le site du Niger, la même année.

Afin de mieux caractériser quantitativement les incertitudes de ces produits, analysons les scores Figure 2.45. Sur cette figure, chaque produit de pluie est évalué pour chaque année en comparaison avec les pluviomètres, pour les deux sites. Les scores utilisés ici sont la corrélation journalière, le RMSE journalier et le biais annuel.

En terme de corrélation, les produits ADJ (pour ADJusted) présentent globalement de meilleurs scores que leur version RAW (*temps-réel*), même si certaines années (2014 pour TRMM au Niger par exemple) semblent modérer ce résultat. Intéressons-nous plutôt au RMSE journalier, synonyme d'erreur journalière moyenne (en millimètres) entre les produits satellites et les pluviomètres. On observe que les produits RAW sont cette fois-ci nettement moins bons que leur pendant ADJ. On remarque aussi que le produit PERSIANN est le plus mauvais sur les deux sites, et sur toutes les années. Pour le biais annuel, ici équivalent au le cumul annuel des pluviomètres moins le cumul annuel des produits satellites, on observe que les produits RAW surestiment toujours. Pour les produits ADJ, ils sont très bons au Niger mais ont tendance à sous-estimer les pluies sur le site du Bénin.

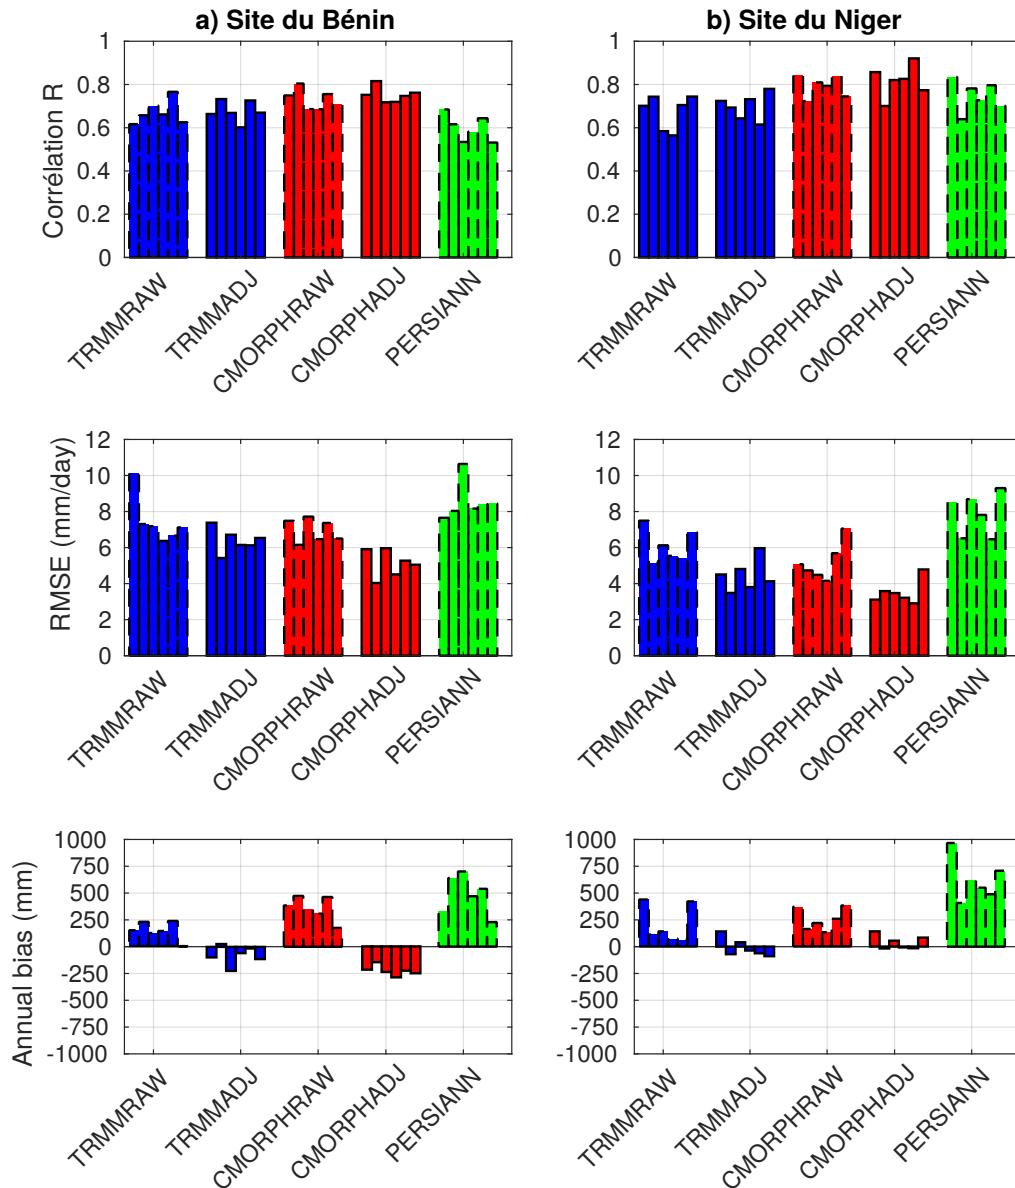


FIGURE 2.45 – Scores de validation des produits de pluies satellites comparées au pluviomètres AMMA-CATCH sur les sites du Bénin (colonne de gauche) et du Niger (colonne de droite) pour les années 2010-2015.

Maintenant que les incertitudes sur les produits de pluies ont été analysées, observons l'effet de ces erreurs en terme d'humidité du sol simulée par le modèle SURFEX et le modèle API. Pour chaque jeu de produits de précipitation, les produits RAW sur SURFEX Figure 2.46 et l'API Figure 2.48, puis les produits ADJ sont utilisés Figure 2.47 pour SURFEX et Figure 2.49 pour l'API et les profils comparés à la simulation de référence, c'est-à-dire celle avec le produit de pluie *in-situ* (trait noir).

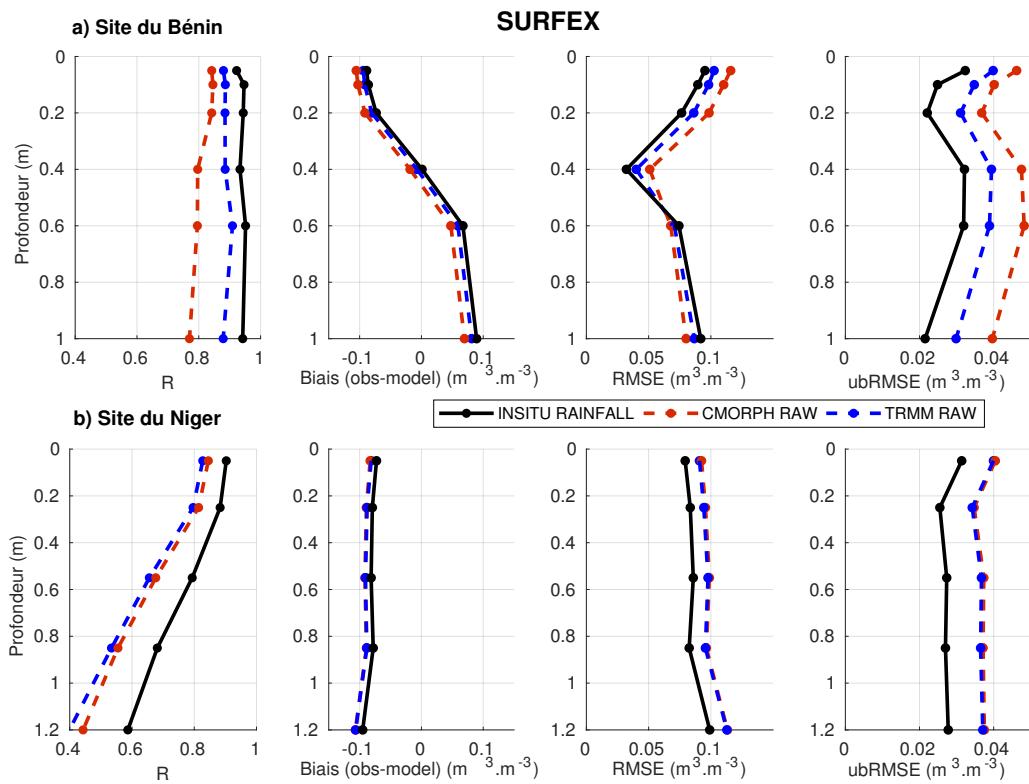


FIGURE 2.46 – Impact des incertitudes des produits de précipitations *temps-réel* sur les simulations d’humidité du sol SURFEX.

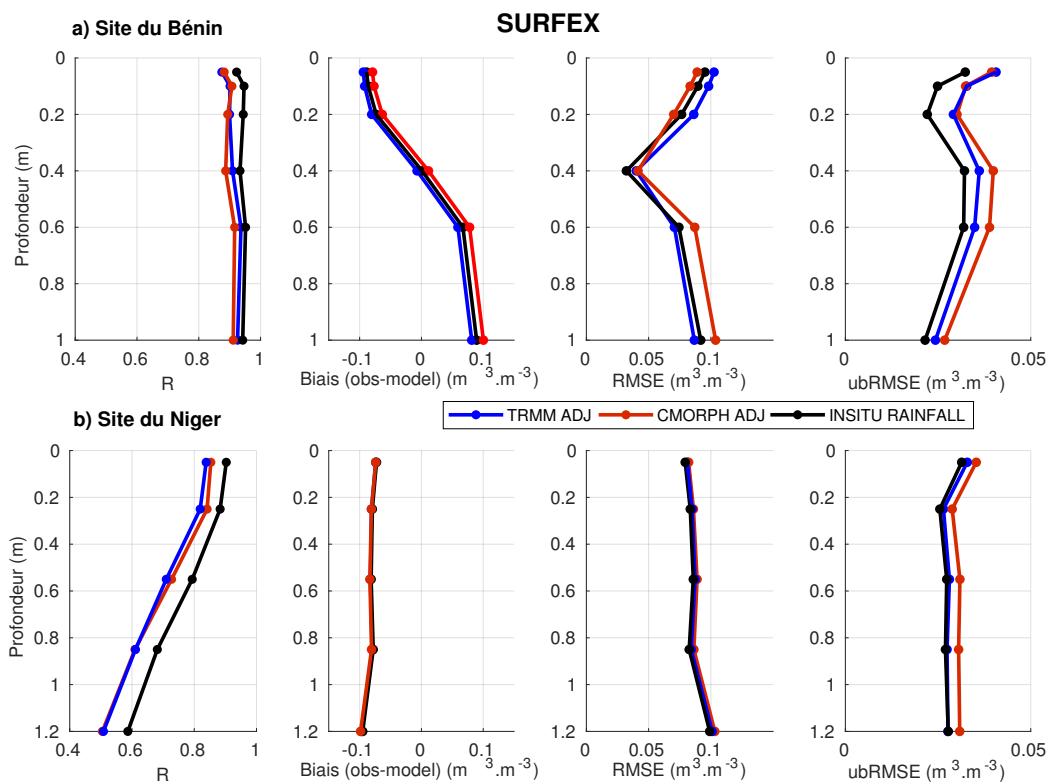


FIGURE 2.47 – Impact des incertitudes des produits de précipitations *ajustés* sur les simulations d’humidité du sol SURFEX.

## 2.5. MODÉLISATION NUMÉRIQUE : SURFEX ET API POUR LA SIMULATION LARGE ÉCHELLE

---

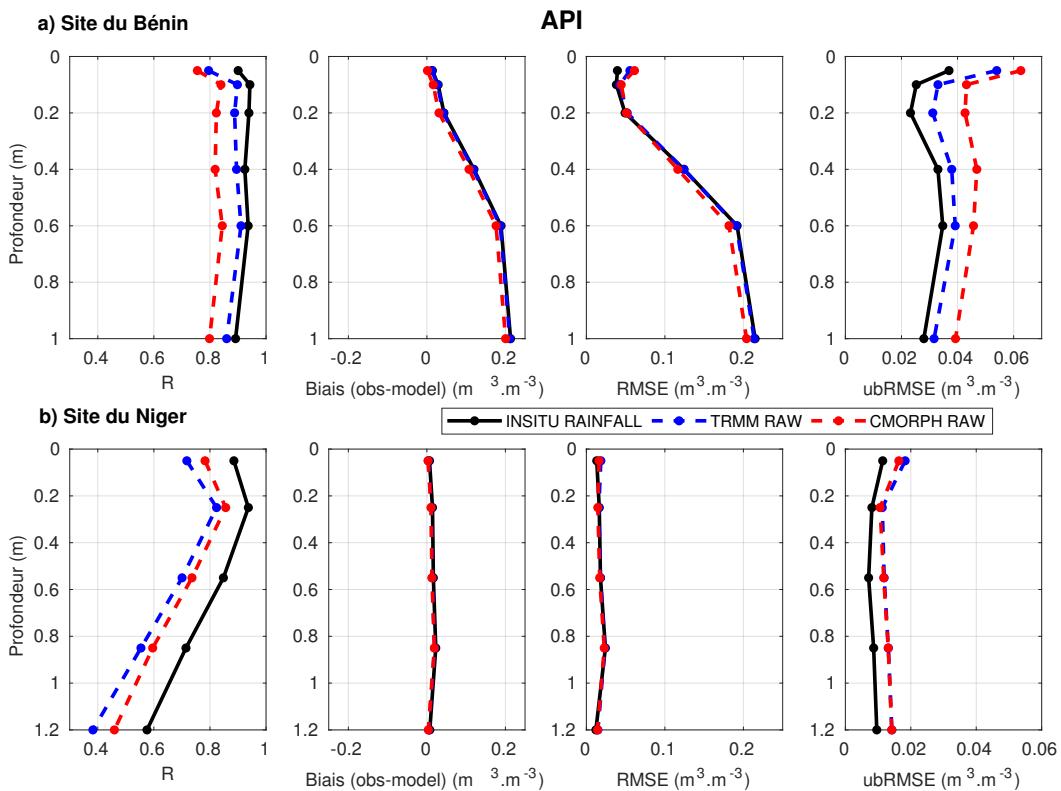


FIGURE 2.48 – Impact des incertitudes des produits de précipitations *temps-réel* sur les simulations d’humidité du sol API.

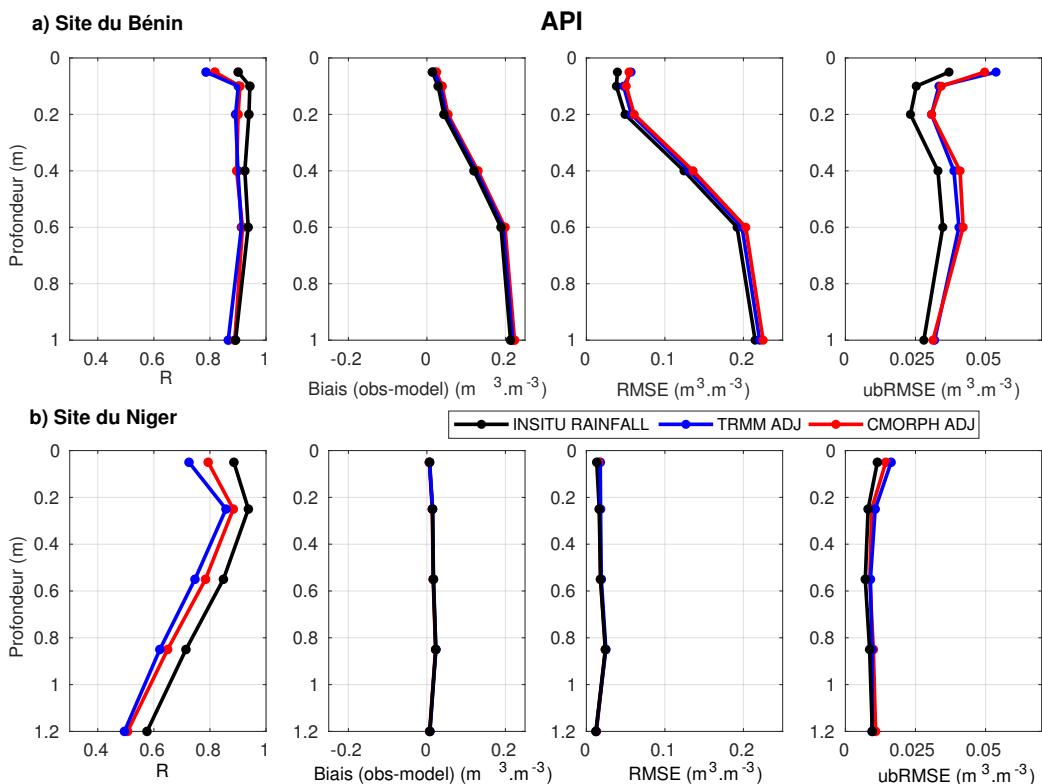


FIGURE 2.49 – Impact des incertitudes des produits de précipitations *ajustés* sur les simulations d’humidité du sol API.

## 2.5. MODÉLISATION NUMÉRIQUE : SURFEX ET API POUR LA SIMULATION LARGE ÉCHELLE

---

Les Figures 2.46 et 2.47 représentent l'impact des erreurs des différents produits de pluies sur les simulations d'humidité du sol SURFEX pour le site du Bénin et du Niger. On observe sur la Figure 2.47, que les scores de corrélation sont faiblement dégradés, de l'ordre de 5 à 10%, le biais et le RMSE ne changent pas énormément. Pour le ubRMSE par contre il est dégradé d'environ  $0.01 \text{ m}^3 \cdot \text{m}^{-3}$  tout le long de la colonne. Pour le site du Niger, les évolutions sont relativement similaires sauf pour le produit TRMMADJ au Niger qui ne génère qu'une très faible dégradation de ubRMSE.

Sur la Figure 2.46 on observe la forte dégradation des scores, en particulier de la corrélation et du ubRMSE lors de l'utilisation des produits RAW. En effet, les profils en pointillés sont plus éloignés du profil de référence noir. L'utilisation du produit CMORPHRAW au Bénin génère par exemple une dégradation de  $0.02 \text{ m}^3 \cdot \text{m}^{-3}$  sur tout la colonne de sol (soit +100% d'erreur) et de plus de  $0.01 \text{ m}^3 \cdot \text{m}^{-3}$  de ubRMSE sur toute la colonne du Niger ( $\sim 50\%$  de dégradation).

Pour le modèle API, c'est-à-dire Figure 2.48 et 2.49, les constats sont relativement similaires, c'est-à-dire une dégradation modérée des scores lorsque les produits ADJ sont utilisés, alors que l'utilisation des données temps-réel RAW dégrade fortement les simulations d'humidité.

## 2.6 Résumé et conclusion

Dans ce chapitre la capacité de différentes méthodes à estimer l'humidité du sol a été évaluée. Dans un premier temps nous avons vu que la mesure d'humidité *in-situ* permettait d'avoir une idée de la profondeur d'infiltration de l'eau à l'échelle locale. Il a aussi été montré que la distance de décorrélation était relativement grande, avec -0.15 point/10 km pour le Niger et moitié moins, -0.075 point/10 km, pour le Bénin.

Dans un second temps, nous avons évalué la qualité des mesures SMOS. Ce dernier permet une mesure de l'humidité à l'échelle globale mais uniquement en surface. La qualité des humidités SMOS est bonne ( $R > 0.7$ ) pour les deux sites lorsqu'elles ne sont pas perturbées par les RFI, comme durant les années 2013 et 2014.

Dans un troisième temps, nous avons fait un exercice de modélisation en comparant dans un premier temps deux modèles, l'API et SURFEX. De cette comparaison nous avons vu que les simulations donnaient de bons résultats sur tout la colonne de sol en terme de variabilité (c'est-à-dire les scores de corrélation et le ubRMSE) lorsque les modèles étaient forcés par les produits de pluie issues de l'observatoire AMMA-CATCH. Toutefois, SURFEX présente un fort biais (en moyenne  $0.1 \text{ m}^3 \cdot \text{m}^{-3}$ ), qui n'est pas présent dans les premiers 50 cm de sol de l'API. Ce biais a donc un fort impact sur le RMSE, et l'augmente considérablement.

Cependant, les pluviomètres ne sont pas disponibles partout, nécessitant donc le recours aux produits de pluie satellite pour pouvoir spatialiser les simulations. Ces derniers souffrant d'incertitudes, nous avons vu que ces erreurs avaient un fort impact sur les simulations, et plus particulièrement dans leur forme temps-réels.

Ci-dessous une synthèse des avantages, inconvénients et incertitudes de chaque méthodes :

TABLE 2.3 – Synthèse sur les méthodes d'estimations d'humidité du sol en Afrique de l'Ouest

Méthode	Mesures <i>in-situ</i> AMMA-Catch	Télédétection SMOS	Modélisation SURFEX/API
Avantage	<ul style="list-style-type: none"> <li>Précision permettant de servir de référence</li> <li>Profils d'infiltration (0-1m)</li> </ul>	<ul style="list-style-type: none"> <li>Mesure globale (3 jours)</li> <li>Bonne qualité dans la zone d'étude</li> </ul>	<ul style="list-style-type: none"> <li>Estimations globales</li> <li>Résolution spatiale/temporelle</li> <li>Profils d'infiltrations</li> </ul>
Inconvénient	<ul style="list-style-type: none"> <li>Peu de points de mesure</li> <li>Observations locales</li> <li>Problèmes de saturations</li> </ul>	<ul style="list-style-type: none"> <li>Incertitude de certaines scènes (végétations, topographies, eau libre,...)</li> <li>Observations discontinues</li> <li>Uniquement en surface (0-5cm)</li> <li>Résolution large (25x25km)</li> <li>RFI</li> </ul>	<ul style="list-style-type: none"> <li>Incertitudes sur les paramétrisations</li> <li>Incertitudes sur les forçages</li> <li>Problématique sur les incertitudes des pluies satellitaire dans leur version temps-réel</li> <li>Biais important</li> </ul>



### Prochain chapitre

Dans ce chapitre les limitations des représentations de l'humidité du sol ont été présentées. Dans le prochain chapitre, une méthode permettant de combiner ces trois méthodes d'estimations, au travers de l'assimilation de données est proposée, afin d'obtenir une information spatialisée, et en profondeur de l'humidité du sol.

# Chapitre 3

## Amélioration des estimations d'humidité du sol à travers l'assimilation de données

---

3.1	Introduction . . . . .	74
3.2	Choix des méthodes d'assimilation . . . . .	74
3.3	Normalisation des données à travers le CDF-Matching . . . . .	78
3.4	Assimilation de SMOS en contraignant l'humidité avec un Simplified Extended Kalman Filter . . . . .	80
3.4.1	Principe du SEKF . . . . .	80
3.4.2	Résultats et discussion . . . . .	82
3.5	Assimilation de SMOS en contraignant les précipitations avec un filtre particulaire . . . . .	85
3.5.1	Principe du filtre particulaire . . . . .	85
3.5.2	Évaluation sur les sites du Bénin et du Niger . . . . .	88
3.5.3	Spatialisation de la méthode . . . . .	91
3.6	Résumé et conclusion . . . . .	94

---

### 3.1 Introduction

Dans le chapitre précédent nous avons vu que la représentation de l'humidité dans le sol à large échelle était impactée par les incertitudes de forçage des modèles. Or dans un souci de spatialisation des simulations le recours aux données de pluies satellites est indispensable. De différentes qualités, ces données ont comme point commun de comporter de fortes incertitudes, en particulier dans leur version temps-réel. Ces incertitudes ont un fort impact sur les simulations d'humidité du sol. Une des solutions pour réduire ces incertitudes est d'utiliser l'assimilation de données pour intégrer les données de télédétection d'humidité du sol dans les modèles de surface.

L'assimilation de l'humidité du sol dans des modèles de surface, ou hydrologiques, est une question abordée depuis plusieurs années dans de nombreuses études ([Houser et al., 1998], [Walker and Houser, 2001], [Margulis et al., 2002], [Reichle et al., 2002], [Reichle and Koster, 2003], [Crow and Wood, 2003], [Seuffert et al., 2003]). En effet, comme vu Figure 1.14, les estimations d'humidité du sol par satellite sont disponibles depuis les années 1980 avec les satellites tels que SMMR, SSM/I, TRMM-TMI, AMSR-E, ASCAT, Windsat, ... L'assimilation de ces produits a permis d'améliorer la modélisation des débits [Pauwels et al., 2001] [Leroux, 2016], d'améliorer les prévisions d'inondations [Brocca et al., 2010] et de sécheresse [Kumar et al., 2014] ou encore l'humidité en zone racinaire [Draper et al., 2012]. Dans notre problématique, nous allons étudier comment combiner SMOS avec les modèles de surface, à l'aide de deux méthodes d'assimilation différentes : le filtre de Kalman étendu simplifié (SEKF), puis à travers le filtre particulaire (PF).

### 3.2 Choix des méthodes d'assimilation

L'assimilation de données est généralement définie comme : *l'ensemble des techniques statistiques qui permettent d'améliorer la connaissance de l'état d'un système à partir de sa connaissance théorique et des observations expérimentales*. Au début du 19ème siècle, les premières techniques de fusion des ces deux sources d'informations sont apparues, permettant de combiner les avantages des observations et des modèles mathématiques pour représenter au mieux un phénomène. L'assimilation de données est issue de la théorie du contrôle (Gelb, Lions), qui étudie le comportement des systèmes dynamiques en fonction de leurs paramètres, et des statistiques.

Le choix du schéma d'assimilation est dépendant de l'application. En effet, en fonction de l'information recherchée, que ce soit un paramètre ou une variable d'état, le schéma à utiliser ne sera pas le même. De nombreux autres facteurs rentrent en jeu dans ce choix, tels que la complexité du modèle, le type d'observation à analyser ou encore le temps de calcul. Il existe de nombreux schémas d'assimilation différents mais en général on les divise en deux grandes classes, la séquentielle et la variationnelle. La séquentielle (a) sur Fig 3.1) revient à prendre en compte les observations temporellement parlant, au fur et à mesure de leur apparition. C'est-à-dire que les observations sont considérées antérieures ou égales au temps de l'analyse. La seconde méthode est dite variationnelle (b) sur Fig 3.1) et utilise toutes les observations disponibles, passées et futures au moment de l'analyse.

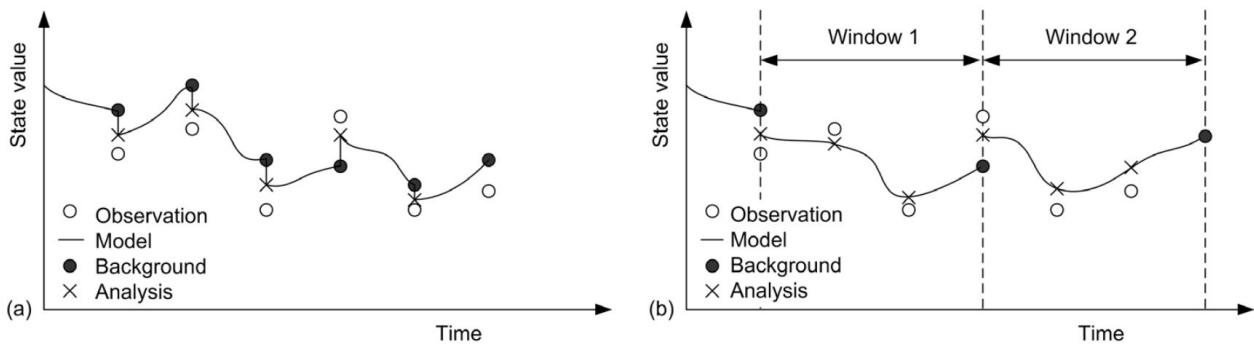


FIGURE 3.1 – Différents types de schéma d'assimilation [Houser et al., 2012].

L'assimilation est le résultat d'une transformation mathématique, appelée l'**analyse**, à partir d'observations,  $\mathbf{y}_o$ , et de prévisions issues d'un modèle, l'**ébauche**,  $\mathbf{x}_b$ . L'objectif est d'utiliser les informations pertinentes de chacune des deux sources pour représenter au mieux l'état réel,  $\mathbf{x}_t$ , du phénomène étudié. Cependant, dans la plupart des cas les observations et le modèle ne sont pas à la même résolution (spatiale et temporelle) et ne représentent pas toujours directement les mêmes paramètres physiques. Pour rendre les deux informations comparables, on utilise alors un opérateur permettant de passer de l'espace des variables du modèle à l'espace des variables des observations, l'**opérateur d'observation  $\mathbf{H}$** . Ce dernier peut donc être un simple interpolateur permettant de faire coïncider les résolutions du modèle et des observations, ou bien un modèle radiatif (tel que le L-MEB présenté précédemment) permettant d'inverser les radiances mesurées par les satellites d'observation en paramètre du modèle.

La différence entre l'observation et l'état estimé du modèle est appelée l'**innovation** :  $\mathbf{y}_o - \mathbf{H}(\mathbf{x}_b)$ . L'innovation reflète la différence de représentation entre l'observation et le modèle. Or comme toute représentation, l'observation et l'ébauche ne sont pas parfaites. Elles sont donc accompagnées d'erreurs qu'il faut prendre en compte pour pondérer l'analyse. On considère alors deux types d'erreur :

- Erreur d'ébauche : l'erreur d'ébauche,  $\mathbf{x}_b - \mathbf{x}_t$ , est l'erreur du modèle par rapport à la réalité. On considère aussi la covariance d'erreur d'ébauche qui représente l'influence spatiale et temporelle d'une analyse sur d'autres points de grille ou physiquement à d'autres variables. On regroupe ces covariances sous la matrice  $\mathbf{B}$ .
- Erreur d'observation : l'erreur d'observation,  $\mathbf{y}_o - \mathbf{H}(\mathbf{x}_t)$ , représente l'erreur de mesure. Sa matrice de covariance  $\mathbf{R}$  représente les interdépendances potentielles d'une erreur de mesure sur une autre.

La définition des erreurs est donc primordiale dans le schéma d'assimilation car ce sont elles qui donnent plus ou moins d'importance à chacune des deux informations en fonction de leur qualité.

Dans le cas séquentiel (partie a) de la Figure 3.1), le résultat de l'analyse (croix) est un compromis entre le modèle (rond noir) et les observations (rond vide). En repartant de cette analyse, le modèle la propage jusqu'à la prochaine observation. Le formalisme mathématique est :

$$x_a = x_b + K(y_o - H(x_b)) \quad (3.1)$$

avec :

$$K = \mathbf{B} \mathbf{H}^T (\mathbf{B} \mathbf{B}^T + \mathbf{R})^{-1} \quad (3.2)$$

Le coefficient  $K$  défini dans l'équation (3.2) permet de pondérer l'innovation dans l'équation (3.1). On quantifie alors la contribution de l'assimilation par l'**incrément** :  $\mathbf{x}_a - \mathbf{x}_b$ . De l'équa-

tion (3.2) on peut déduire que si le modèle est très précis par rapport à l'observation, alors  $\mathbf{B} < \mathbf{R}$  et  $K$  est petit. Ce qui a pour incidence de ne pas beaucoup modifier l'analyse et donc un incrément faible. Au contraire, si l'observation s'avère de meilleure qualité alors  $\mathbf{R} < \mathbf{B}$ ,  $K$  sera grand, et l'incrément sera grand. Parmi ces méthodes séquentielles on identifie l'interpolation optimale (OI) ou encore les différents filtres de Kalman.

Le cas variationnel revient quant à lui à chercher l'état analysé  $\mathbf{x}_a$  qui minimise une fonction de coût en prenant en compte les observations comprises dans la fenêtre :

$$J(x) = J^b(x - x_b) + J^o(y_o - H(x)) \quad (3.3)$$

$\mathbf{J}^b$  est la mesure de la différence entre l'ébauche et l'état analysé que l'on cherche.  $\mathbf{J}^o$  est la mesure de la différence entre l'observation et l'état projeté de l'analyse. Ainsi en cherchant la dérivée égale à 0 de (3.3) par rapport à la variable que l'on veut analyser on obtient l'estimation optimale. On retrouve les célèbres 3D-VAR, 4D-VAR, ...

Le choix de la méthode d'assimilation est dépendant de nombreux paramètres, tels que la potentiellement non-linéarité du modèle ou encore le temps de calcul. Notre choix s'est d'abord orienté vers le Simplified Extended Kalman Filter (SEKF). Utilisé en opérationnel par Météo France, il est historiquement lié à SURFEX. Nous verrons par la suite qu'il permet de contraindre la trajectoire d'humidité en fonction des observations. Cependant cette modification interne au modèle génère d'autres problématiques. La principale source d'erreur étant liée aux incertitudes sur les précipitations une seconde méthode est alors testée, le filtre particulaire (PF). La principale différence conceptuelle de ces 2 schémas réside dans le fait que le PF utilise les observations pour "réduire" directement les erreurs de forçages alors que le SEKF utilise les observations pour corriger la trajectoire dans le modèle (voir Figure 3.2).

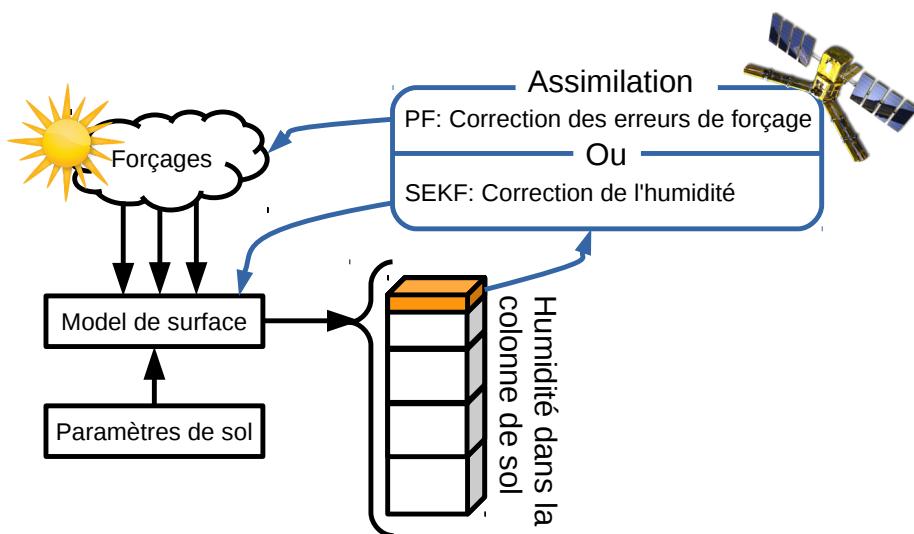


FIGURE 3.2 – Deux concepts différents, soit les erreurs de forçage sont corrigées avec le PF, soit les humidités sont séquentiellement ajustées avec le SEKF.

Afin de représenter ces 2 méthodes, analysons le schéma Figure 3.3. Sur la partie a), on observe le SEKF, avec la trajectoire d'humidité simulée séquentiellement ajustée à chaque observation de SMOS. Sur le schéma b), le PF, l'événement de précipitation est perturbé de manière à générer un ensemble de trajectoires d'humidités simulées. Ensuite, les observations SMOS sont utilisées pour choisir la trajectoire la plus pertinente.

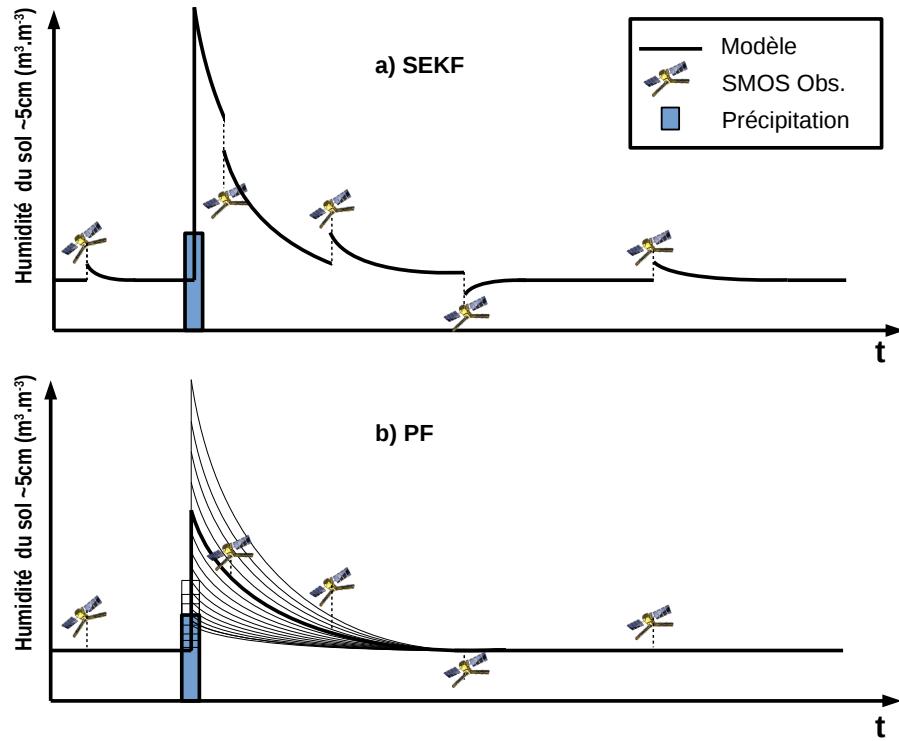


FIGURE 3.3 – Schématisation des 2 méthodes d'assimilation. Soit le SEKF en a), soit le PF en b).

### 3.3 Normalisation des données à travers le CDF-Matching

Avant d'assimiler les observations dans le modèle, il est important d'étudier leurs dynamiques respectives. En effet, comme montré précédemment, un biais important existe entre les données de télédétection et la modélisation. Ce biais fort est un obstacle à l'assimilation car une prise en compte d'une observation trop humide par rapport à la dynamique du modèle viendrait à dégrader la représentation de l'humidité, et vice et versa. Plusieurs méthodes permettent alors de corriger ce problème. La première est de calibrer le modèle de manière à ce que la dynamique de l'humidité modélisée puisse être comparable aux observations satellite ([Wanders et al., 2014a], [Wanders et al., 2014b]). Cependant cette méthode a souvent des effets néfastes sur les autres composantes du modèle, et tend ainsi à le "déséquilibrer". Une autre solution, appelée CDF Matching (pour Cumulative Distribution Fonction), réside en une "mise à l'échelle" des observations avec le modèle avant que ces dernières soient assimilées ([Reichle and Koster, 2004], [Liu et al., 2009]). Cette méthode consiste ajuster de la moyenne et l'écart-type des observations avec le modèle. L'une des principales critiques de cette méthode est que l'observation perd donc sa valeur absolue. Pour effectuer le CDF Matching, on utilisera les deux coefficients ci-dessous :

$$p2 = \frac{std(Insitu)}{std(SMOS)} \quad (3.4)$$

$$p1 = Insitu - p2 \times SMOS \quad (3.5)$$

$$SMOS_{CDF} = p1 + p2 \times SMOS \quad (3.6)$$

En appliquant les coefficients sur les séries temporelles Figure 3.4 on obtient la Figure 3.5.

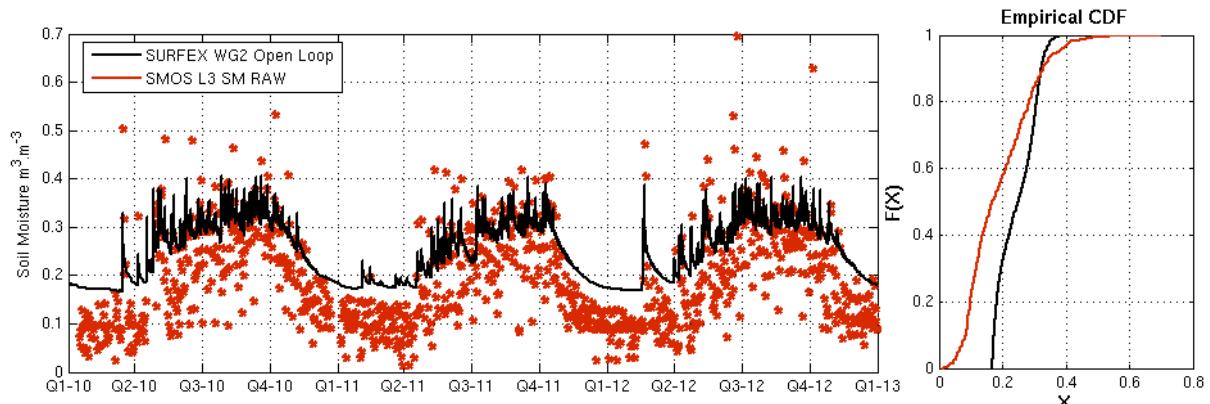


FIGURE 3.4 – Sur la gauche on observe le biais entre les mesures SMOS et les simulations SURFEX. À droite, la distribution des cumuls de chacune des séries temporelles.

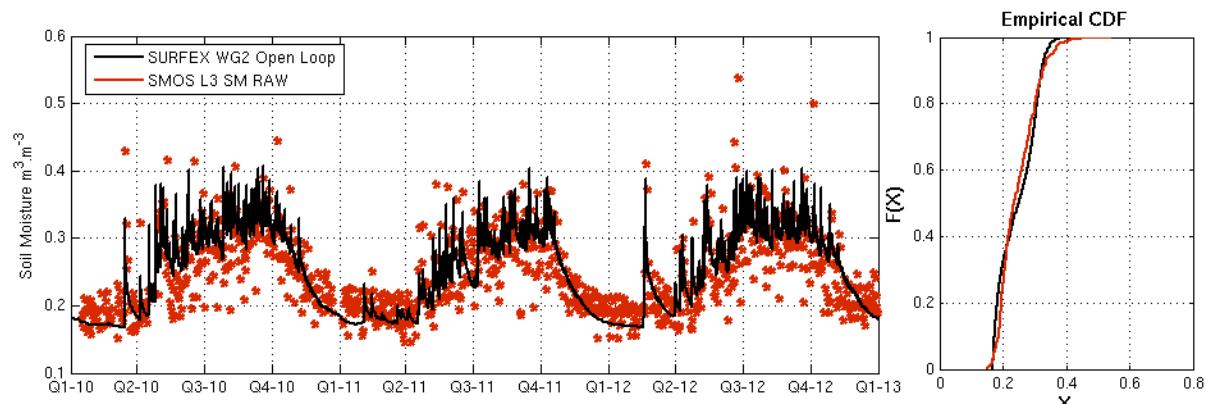


FIGURE 3.5 – Même figure que 3.4 après application des coefficients.

La question de la période utilisée pour faire le CDF-matching a aussi son importance. Par exemple là où certaines études se basent sur la climatologie de l'ensemble des données, d'autres préconisent plutôt de produire des coefficients par saison, mois, ... Après une étude de sensibilité, on utilisera dans cette étude un CDF Matching basé sur la climatologie globale. Dans le cas de la spatialisation des simulations, il est nécessaire de calculer les coefficients p1/p2 pour chacun des pixels. On peut ainsi représenter les coefficients sous forme de cartes présentées Figure 3.6 et 3.7.

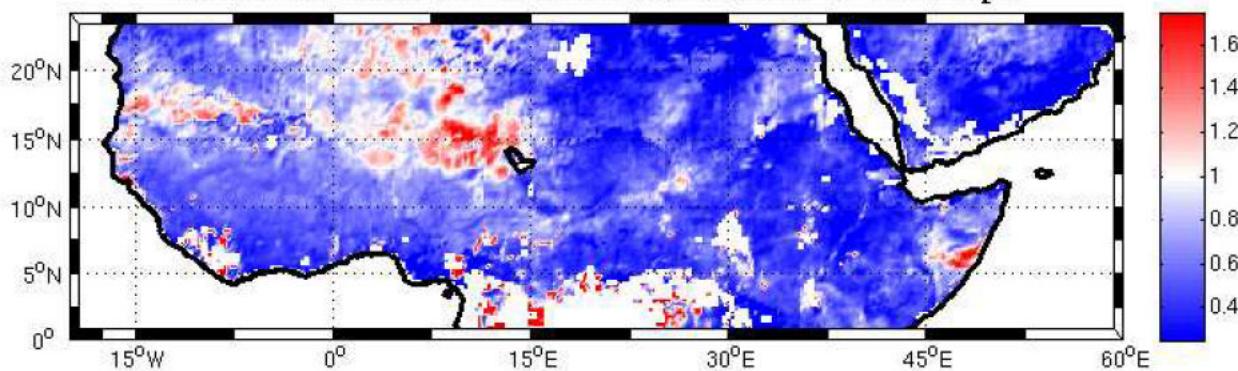


FIGURE 3.6 – Carte des coefficients P2 entre SMOS et SURFEX (forcé par des pluies CMORPH Adj).

Sur la carte 3.6 est représenté le coefficient P1 pour l'année 2010. On observe donc les différences de dynamique entre les observations SMOS et la modélisation SURFEX, ici forcé avec des pluies CMORPH ADJ.

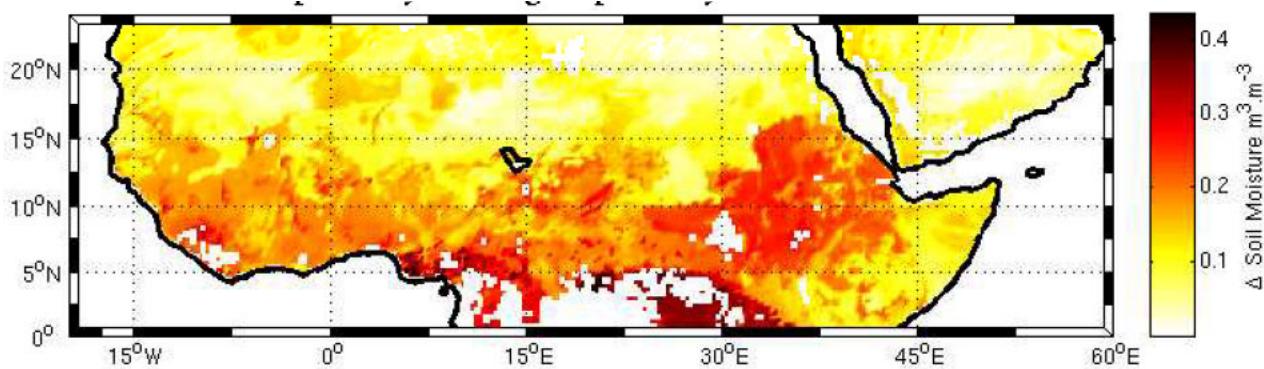


FIGURE 3.7 – Carte des coefficients P1.

## 3.4 Assimilation de SMOS en contraignant l'humidité avec un Simplified Extended Kalman Filter

### 3.4.1 Principe du SEKF

Le schéma d'assimilation utilisé ici est un Simplified Extended Kalman Filter (SEKF), inspiré de la description de celui utilisé dans la thèse de Marie Parrens (2012). Rappelons ici quelques équations et le principe de ce filtre. Dans [Mahfouf et al., 2009] est présenté un filtre de Kalman Etendu Simplifié. La principale différence avec un filtre de Kalman "classique" est que les équations de propagation sont non-linéaires (Etendu) et que la matrice de covariance d'erreur modèle  $\mathbf{B}$  n'évolue pas au cours du temps (Simplified). Cette adaptation est nécessaire pour prendre en compte les non-linéarités du modèle au cours du temps, il est utilisé ici une linéarisation du modèle à travers le tangent linéaire  $\mathbf{H}$ . Voilà un synoptique du schéma utilisé :

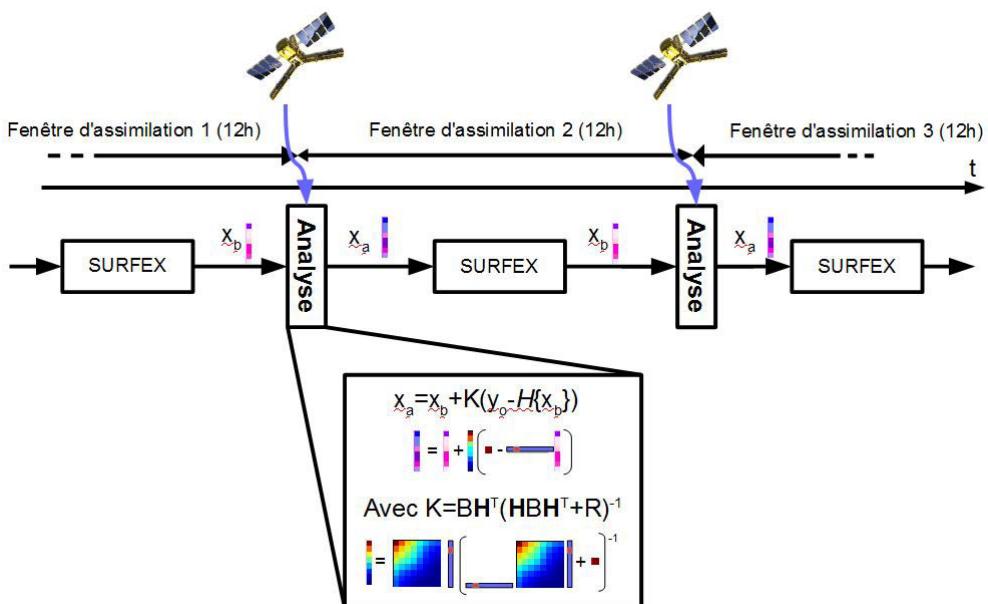


FIGURE 3.8 – Description synoptique de l'assimilation séquentielle avec le SEKF.

Détaillons un peu ce schéma. La simulation est découpée en  $n$  fenêtres d'assimilation. Ces fenêtres d'assimilation sont calées en fonction du passage de SMOS sur la zone (pour une même journée), les fenêtres sont donc bornées respectivement à 6h et 18h (heure de passage du satellite). La séquence se déroule alors comme suit :

- Paramétrisation du modèle et découpage des forcages associés au temps  $t$  de la fenêtre
- Trois cas se présentent alors :
  - Si  $t=0$ , premier pas de temps, alors on initialise le modèle avec l'état final d'une simulation antérieure (Spin up).
  - Si pas d'observation SMOS alors on initialise le modèle avec l'état final de la fenêtre précédente  $x_a(t) = x_b(t - 1)$  et on lance le modèle sur la fenêtre

$$x_b(t + 1) = M(t \rightarrow t + 1)x_a(t) \quad (3.7)$$

- S'il y a présence d'une observation SMOS, on relance le calcul trois fois pour la fenêtre d'assimilation de manière à calculer le tangent linéaire permettant d'évaluer la linéarité du modèle et donc la propagation de ses erreurs :

### 3.4. ASSIMILATION DE SMOS EN CONTRAIGNANT L'HUMIDITÉ AVEC UN SIMPLIFIED EXTENDED KALMAN FILTER

1. Première simulation,  $run_{ref}$ , initialisée avec état final de la fenêtre précédente  $x_a(t) = x_b(t - 1)$ .
2. Seconde simulation, on perturbe l'initialisation de  $run_{ref}$  avec  $\delta x = 0,0001 \text{ m}^3 \cdot \text{m}^{-3}$  (??) et on calcul le tangent linéaire :

$$\mathbf{H} = \frac{H(x + \delta x) - H(x)}{\delta x} \quad (3.8)$$

On calcul ensuite le gain de Kalman :

$$K = B\mathbf{H}^T(\mathbf{H}\mathbf{B}\mathbf{H}^T + R)^{-1} \quad (3.9)$$

On peut donc maintenant calculer l'analyse :

$$x_a = x_b + K(y_o - H(x_b)) \quad (3.10)$$

Puis on lance le modèle sur la fenêtre d'assimilation.

Ainsi, le modèle prend en compte les observations SMOS à chaque fois qu'il y en a, à travers le membre  $y_o - H(x_b)$ , l'*innovation* pondérée par un gain K. Le tangent linéaire  $\mathbf{H}$  permet de tester la linéarité du modèle au cours de la fenêtre. Ainsi, si la perturbation n'a rien changé, alors  $\mathbf{H}=0$  et  $K=0$ , l'innovation n'a pas d'effet. Si la perturbation s'est propagée linéairement, alors  $\mathbf{H}=1$  et K dépend uniquement des incertitudes (des observations et du modèle). Si le modèle diverge lors de l'incrément alors K devient très petit et l'innovation n'a pas d'effet.

L'équation (3.9) permet de donner plus ou moins d'importance aux observations. Si on reprend schématiquement l'assimilation présentée ici :

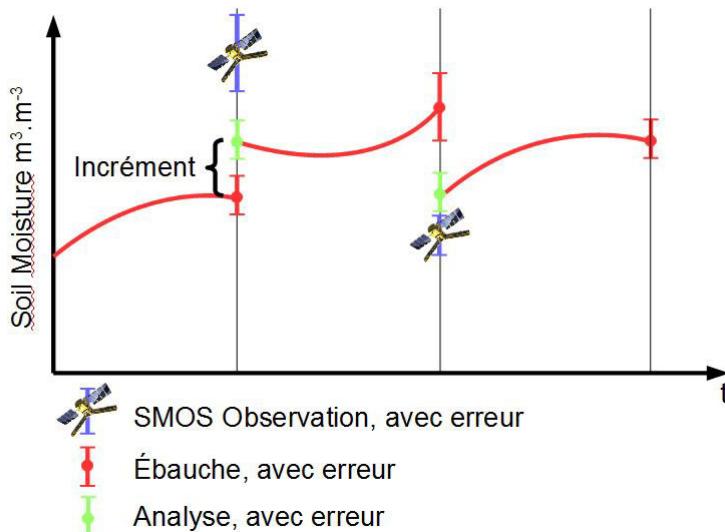


FIGURE 3.9 – Lors de l'assimilation, les erreurs B et R pondèrent l'importance de l'incrément, ce qui permet d'ajuster la trajectoire soit plus près des observations, soit plus près du modèle.

Ainsi, si le modèle a une erreur plus grande que l'observation, l'analyse sera plus proche de l'observation que de l'ébauche, et inversement.

## 3.4. ASSIMILATION DE SMOS EN CONTRAIGNANT L'HUMIDITÉ AVEC UN SIMPLIFIED EXTENDED KALMAN FILTER

### 3.4.2 Résultats et discussion

Une première expérience a été réalisée en implémentant le SEKF dans SURFEX. Le premier test a consisté en l'étude de la paramétrisation du filtre, en particulier les matrices B et R. Ces deux matrices sont critiques dans le modèle car elles gèrent à la fois la balance observation/-modèle mais aussi la propagation de l'incrément dans le sol. En effet, dans l'équation (3.9), le coefficient K qui vient pondérer l'innovation, dépend des matrices décrites Figure 3.8.

Dans un premier temps intéressons-nous à l'impact de la correction sur la couche assimilée, c'est-à-dire la seconde couche de SURFEX (WG2). Pour mieux observer l'effet de la définition des matrices d'erreurs, l'hypothèse de linéarité est effectuée ici, c'est-à-dire que le tangent linéaire n'est pas calculé et que l'opérateur d'observation H est à 1 sur la seconde couche. Cette couche correspond à la couche de 0.01 m à 0.05 m dans la discrétisation de la colonne de sol. Sur la Figure 3.10 est représentée l'impact des observations SMOS sur la trajectoire d'humidité simulée. On remarque qu'en définissant une matrice R très fortement supérieure à B, c'est-à-dire en définissant l'erreur de SMOS très supérieure à l'erreur modèle (K souvent proche de 0), l'analyse ne prend pas en compte les observations SMOS (trajectoire bleue). Lorsque l'on met les mêmes erreurs à SMOS et à SURFEX, on obtient la trajectoire verte puis lorsque l'erreur SMOS est définie comme très faible on obtient la trajectoire rouge. On observe alors que lorsque l'incrément est effectué sur la seconde couche, le modèle réajuste très rapidement la trajectoire et l'effet de SMOS s'apparente plus à des "sauts" d'humidité. Ce phénomène provient de la définition de la structure de la matrice B. En effet, en la définissant diagonale, l'effet de l'incrément ne s'effectue que sur la seconde couche. Ce qui signifie que les couches en profondeur ne sont pas directement impactées par cet incrément et que l'effet est vite atténué par le modèle.

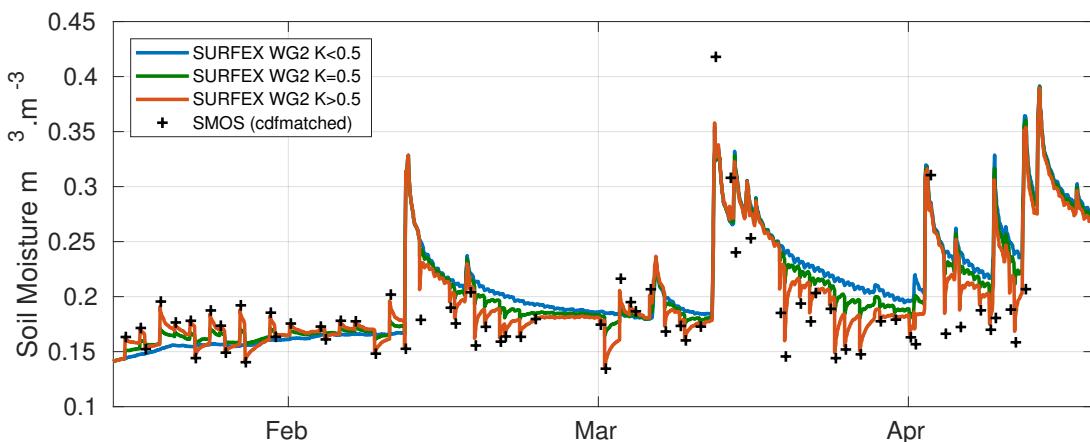


FIGURE 3.10 – Impact de la paramétrisation des matrices d'erreurs sur le schéma d'assimilation. En bleu lorsque les erreurs SMOS sont supposées très fortes, en vert égales à celle du modèle et en rouge plus faibles que le modèle.

Afin de mieux propager cet incrément, une matrice B, cette fois-ci pleine, a été définie en calculant les covariances entre chacune des couches :

$$\mathbf{B} = \begin{bmatrix} Var(WG1) & Cov(WG1, WG2) & \dots \\ Cov(WG2, WG1) & Var(WG2) & \dots \\ \dots & \dots & \dots \end{bmatrix}$$

De cette manière, l'incrément se propage sur toute la colonne de sol. On obtient alors la Figure 3.11. Contrairement à la Figure 3.10 cette fois-ci l'incrément se maintient dans le temps car

### 3.4. ASSIMILATION DE SMOS EN CONTRAIGNANT L'HUMIDITÉ AVEC UN SIMPLIFIED EXTENDED KALMAN FILTER

c'est toute la colonne qui est impactée.

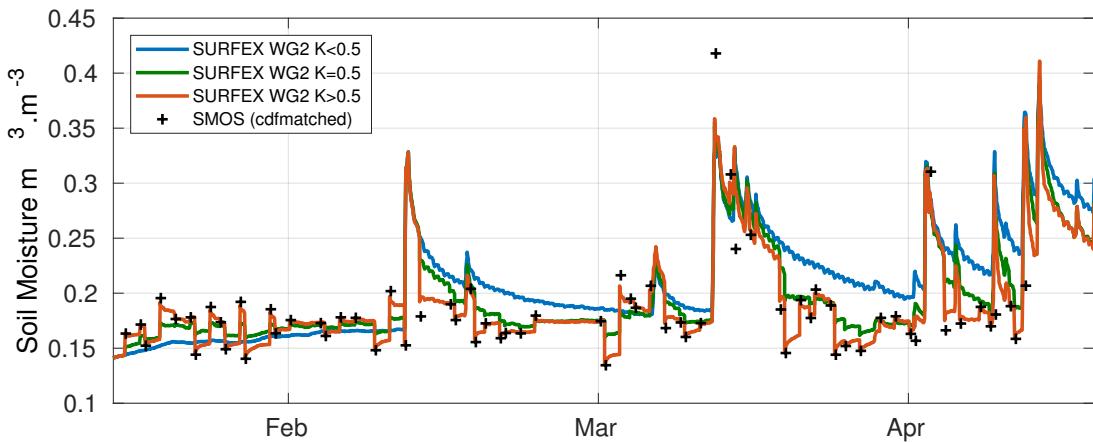


FIGURE 3.11 – Similaire à la Figure 3.10 mais cette fois, il y a propagation de l'incrément en profondeur.

Afin d'observer l'impact de l'assimilation, et du potentiel correctif sur toute la colonne de sol, prenons l'exemple de l'année 2011 pour le site du Bénin. Sur la Figure 3.12 on peut observer, figure du haut la différence entre 2 simulations, lorsque SURFEX est forcé par les pluies CMORPHRAW et forcé par les pluies *in-situ*.

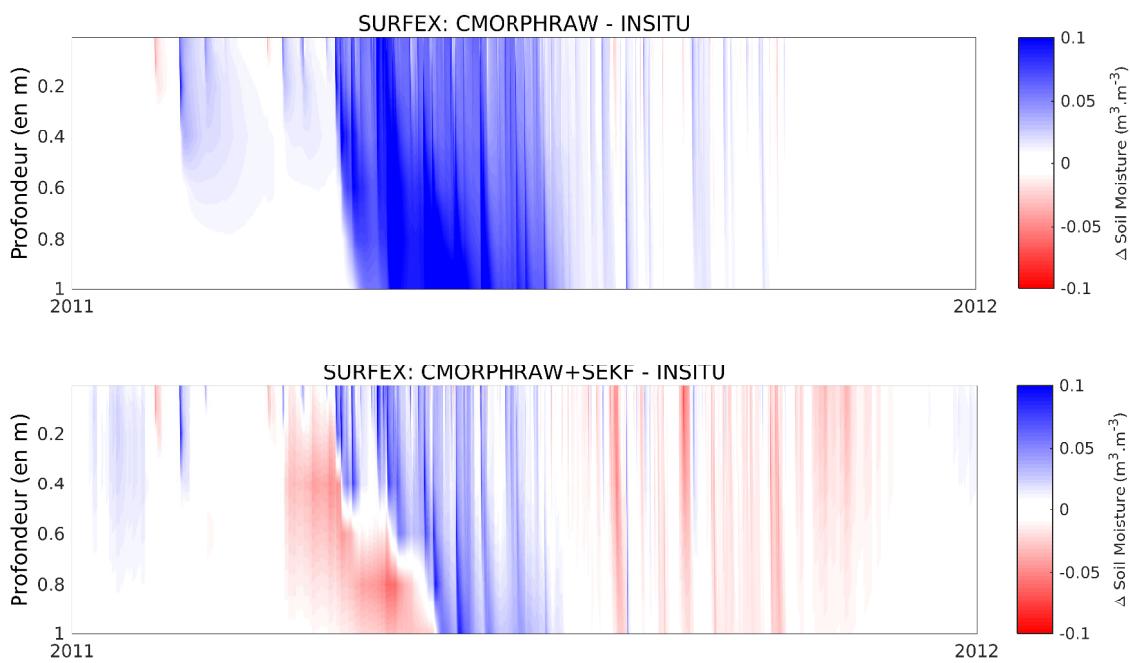


FIGURE 3.12 – Profil d'innovation lors d'assimilation uniquement sur la seconde couche, en haut, et sur toute la colonne, en bas.

On observe un surplus d'eau important dans le sol (jusqu'à plus de 10%), notamment en début de saison des pluies, lorsque SURFEX est alimenté par les précipitations CMORPHRAW (cette erreur peut avoir un fort impact lorsque la méthode est utilisée pour des applications

### 3.4. ASSIMILATION DE SMOS EN CONTRAIGNANT L'HUMIDITÉ AVEC UN SIMPLIFIED EXTENDED KALMAN FILTER

agronomiques). Sur la figure du bas on peut observer la colonne de sol après assimilation. Cette fois ci, l'excès d'eau à été réduit et on peut voir apparaître un assèchement excessif de l'humidité (partie rouge).

De cette première expérience, plusieurs points ont arrêté le développement de ce schéma :

- La sensibilité aux erreurs d'observation. Il nous est paru complexe de quantifier les erreurs d'observations SMOS.
- La sensibilité du schéma aux variations de SMOS pendant la saison sèche est assez forte. Cela a pour effet d'ajouter ou de retirer de l'eau pendant la saison sèche (voir Figure 3.12).
- La difficulté de la paramétrisation du filtre (incrément pour le tangent-linéaire, matrice de propagation, ...).
- Le schéma ne prend pas en compte les erreurs de forçage, or ici les précipitations sont les principales sources d'incertitude (voir les scores 2.5.4).

## 3.5 Assimilation de SMOS en contraignant les précipitations avec un filtre particulaire

### 3.5.1 Principe du filtre particulaire

La seconde méthode d'assimilation décrite ici est inspirée de la méthode du filtre particulaire. Le filtre particulaire (ou méthode de Monte Carlo séquentielle) est une méthode d'assimilation séquentielle basée sur l'estimation d'une densité de probabilité d'état d'une variable. Bien adapté pour les modèles non-linéaires, elle est de plus en plus utilisé dans les géosciences. [Blayo et al., 2014] est un document synthétisant les spécificités de ce filtre, avec le formalisme mathématique, les problématiques de rééchantillonnage, de dégénérescence.

Le principe du filtre dans notre contexte est de perturber les forçages incertains de manière à générer un ensemble de trajectoires du modèle répondant à cet ensemble de perturbations. Dans notre cas cela revient à perturber les précipitations incertaines afin de générer un ensemble de trajectoires d'humidité du sol. L'étape suivante consiste à extraire les trajectoires les plus probables selon leur proximité avec les observations SMOS.

La Figure 3.13 représente ces 4 étapes qui sont détaillées par la suite.

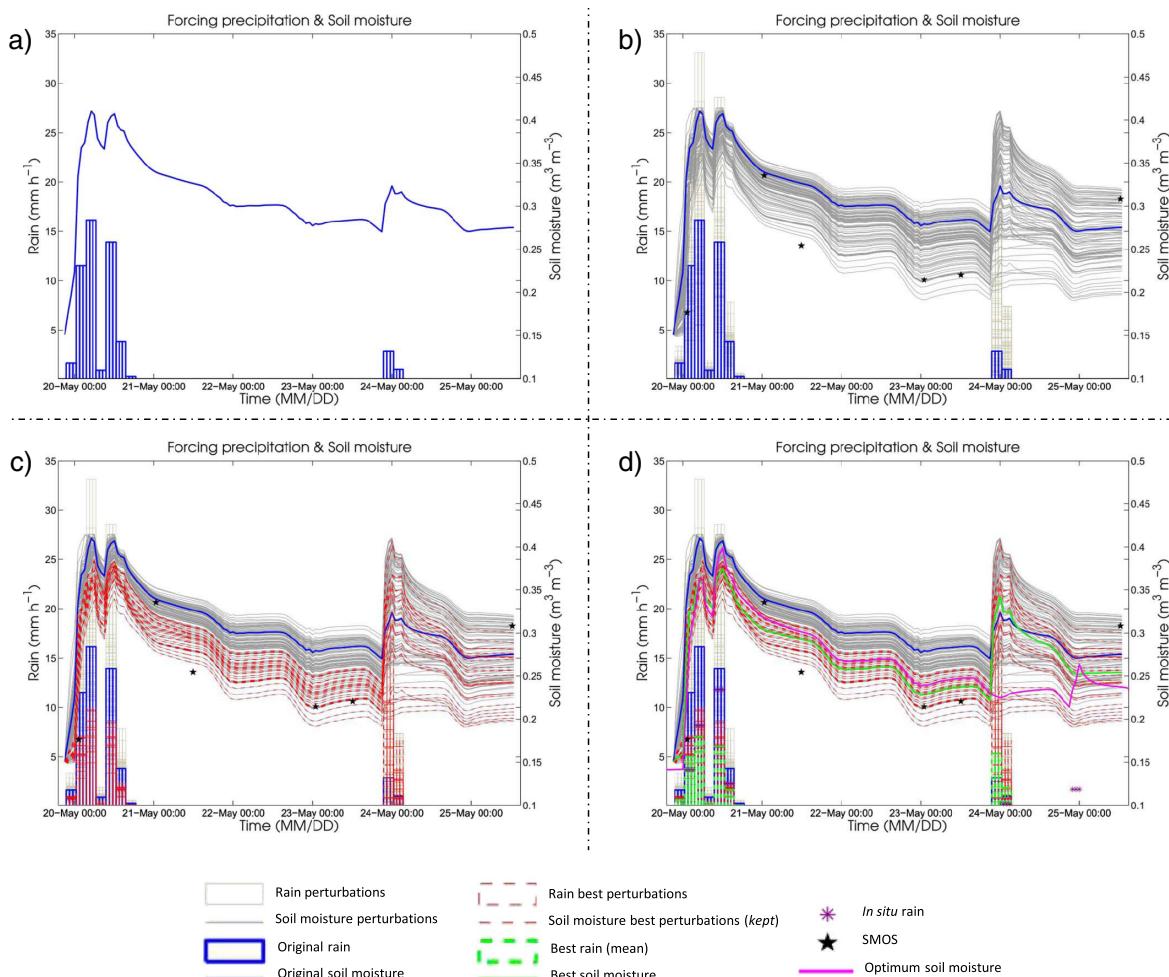


FIGURE 3.13 – La méthode d'assimilation mise en place ici se divise en 4 étapes principales. La première, a), est la simulation de l'humidité du sol (trait plein bleu) à partir du produit de pluie (barres bleues) à corriger. Ce produit de pluie est ensuite perturbé afin de créer un ensemble de trajectoires (courbes grises) en b), puis échantillonné selon les observations SMOS (courbes rouges) en c) et corrigé (courbes vertes) en d).

### 3.5. ASSIMILATION DE SMOS EN CONTRAIGNANT LES PRÉCIPITATIONS AVEC UN FILTRE PARTICULAIRE

Description simplifiée de la Figure 3.13 :

- **Partie a) :**

Le modèle (API ou SURFEX) est lancé à partir des produits de pluies que l'on veut corriger (barres bleues), par exemple CMORPHRAW. Cela génère donc une trajectoire d'humidité en réponse à cette précipitation (courbe bleue).

- **Partie b) :**

Dans un second temps les précipitations sont perturbées puis le modèle est relancé à partir de chaque précipitation perturbée. On obtient ainsi un ensemble de trajectoires d'humidité (en gris sur la Figure 3.13).

- **Partie c) :**

Une fois l'ensemble créé, les "meilleures" trajectoires sont sélectionnées (trajectoires rouges), c'est-à-dire qu'un certain pourcentage de celles qui minimisent le RMSE par rapport aux observations SMOS sont sélectionnées. On sélectionne donc les précipitations correspondantes à ces "meilleures" trajectoires (barres rouges).

- **Partie d) :**

À partir des précipitations sélectionnées (en rouge), la moyenne est calculée. Cette moyenne permet d'obtenir un nouvel événement de pluie (barre verte). Cette nouvelle pluie est réinjectée dans le modèle (trajectoire verte). On obtient ainsi une nouvelle trajectoire d'humidité, ligne verte. Puis on passe à la fenêtre suivante. La fenêtre suivante est donc initialisée par la valeur d'humidité corrigée en fin de fenêtre.

En effectuant cette opération, la nouvelle trajectoire d'humidité respecte l'équilibre du modèle et intègre les observations SMOS. Cependant, certains paramètres sont à définir :

- **Durée de la fenêtre d'assimilation :**

La durée de la fenêtre d'assimilation est conditionnée par deux critères. Le premier est le nombre d'observations SMOS et le second est le nombre de jours. Des études de sensibilité ont montré que le nombre de mesures SMOS optimal est de cinq (voir Figure 3.14). Dans le cas où peu de mesures SMOS sont disponibles, la fenêtre d'assimilation maximale a été définie à neuf jours.

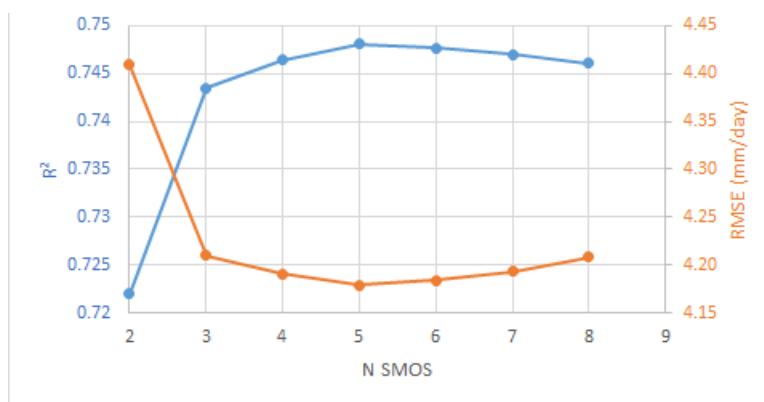


FIGURE 3.14 – Le nombre d'observations SMOS utilisées est fixé à cinq.

- **Méthode de perturbation :**

La méthode de perturbation, caractérisée par le nombre de membres et la distribution des perturbations, est fondamentale dans cette méthode, elle est intimement liée à la qualité de l'assimilation. En effet, il faut s'assurer que le nombre et l'amplitude des perturbations soient suffisants pour "envelopper" les observations SMOS.

### 3.5. ASSIMILATION DE SMOS EN CONTRAIGNANT LES PRÉCIPITATIONS AVEC UN FILTRE PARTICULAIRE

---

L'ensemble de perturbations peut donc être défini comme :

$$P_i(t) = k_i \times P(t) \quad \text{avec } i = 1 : 100 \quad (3.11)$$

avec  $P(t)$  la chronique de précipitation sur la fenêtre d'assimilation et  $P_i(t)$  l'ensemble des 100 membres de précipitations aléatoirement perturbées.

La définition du coefficient multiplicateur  $k$  est la suivante :

$$k = e^{(4rand)-2} \quad (3.12)$$

Cela permet de multiplier les événements de pluies de 0.1353 à 7.3891 fois. Nous verrons plus en détail cette partie dans le [Chapitre 5](#).

- **Méthode d'échantillonnage :**

C'est là que la qualité des observations entre en jeu. En effet la qualité de SMOS est le paramètre qui vient déterminer le nombre de trajectoires que l'on va sélectionner. Pour définir la qualité de SMOS un indice composite a été créé pour cette application, le  $Q_{SMOS}$  :

$$Q_{SMOS} = \frac{(dqx/0.045) + (RFI/0.45) + (Chi2 - 1)/(3.5 - 1)}{3} \quad (3.13)$$

cet indice varie de 0 à 1 en fonction des variations normalisées des indices de qualité de SMOS présentés dans la partie *Indices de qualité de SMOS* (0 et 1 représentant la plus haute et la plus basse qualité, respectivement). Le principe est, comme vu au début de ce chapitre, de venir accorder plus de confiance à l'observation lorsqu'elle est de bonne qualité et vice et versa. Pour cela on utilise ici la fonction décrite Figure 3.15. Le nombre de membres sélectionné varie alors de 10 à 60 en fonction de l'indice de qualité de SMOS. Plus SMOS est "mauvais", plus  $Q_{SMOS}$  sera proche de 1 et plus on augmentera le nombre de membres sélectionnés. Le fait d'augmenter le nombre de membre sélectionné permet d'élargir le "champ des possibles" de trajectoires d'humidité.

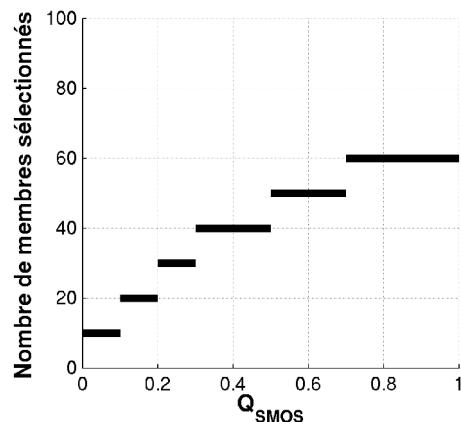


FIGURE 3.15 – Nombre de membres sélectionnés en fonction de la qualité des observations  $Q_{SMOS}$ .

- **Initialisation des fenêtres**

L'initialisation de la fenêtre suivant un ensemble de membres ré-échantillonnés par une distribution gaussienne a été implémentée dans une autre version encore à l'étude au laboratoire. Cela modifie les résultats de manière très infime. La moyenne des trajectoires minimisant le RMSE est donc conservée ici.

### 3.5.2 Évaluation sur les sites du Bénin et du Niger

L'objectif de l'assimilation par le filtre particulier dans notre contexte est de réduire les incertitudes de forçage sur les précipitations afin d'améliorer la représentation de l'humidité du sol en profondeur dans les modèles de surface.

Après avoir assimilé les jeux de précipitations, tel que CMORPHRAW dans le schéma d'assimilation précédent, analysons son effet sur l'humidité du sol. Dans l'article issu de ces travaux [Román-Cascón et al., 2017], une comparaison entre l'application du PF décrit précédemment dans SURFEX et dans l'API est effectuée. L'étude montre que le schéma d'assimilation est plus efficace via l'API que via SURFEX dans le cas de la correction des précipitations. Nous présenterons donc ici les résultats uniquement pour l'API.

Sur la Figure 3.16 est représenté le résultat d'assimilation sur le site du Bénin en 2011 pour l'API. Sur le graphique du haut, on observe la différence d'humidité du sol simulée par le modèle quand il est forcé par les pluies CMORPHRAW et les pluies *in-situ*. On observe, comme sur la Figure 3.12, une surestimation de l'humidité en début de saison des pluies. Sur le graphique du bas on peut observer l'humidité du sol simulée par le modèle quand il est forcé par les pluies CMORPHRAW assimilées et les pluies *in-situ*. On observe alors une réduction de cette surestimation globale.

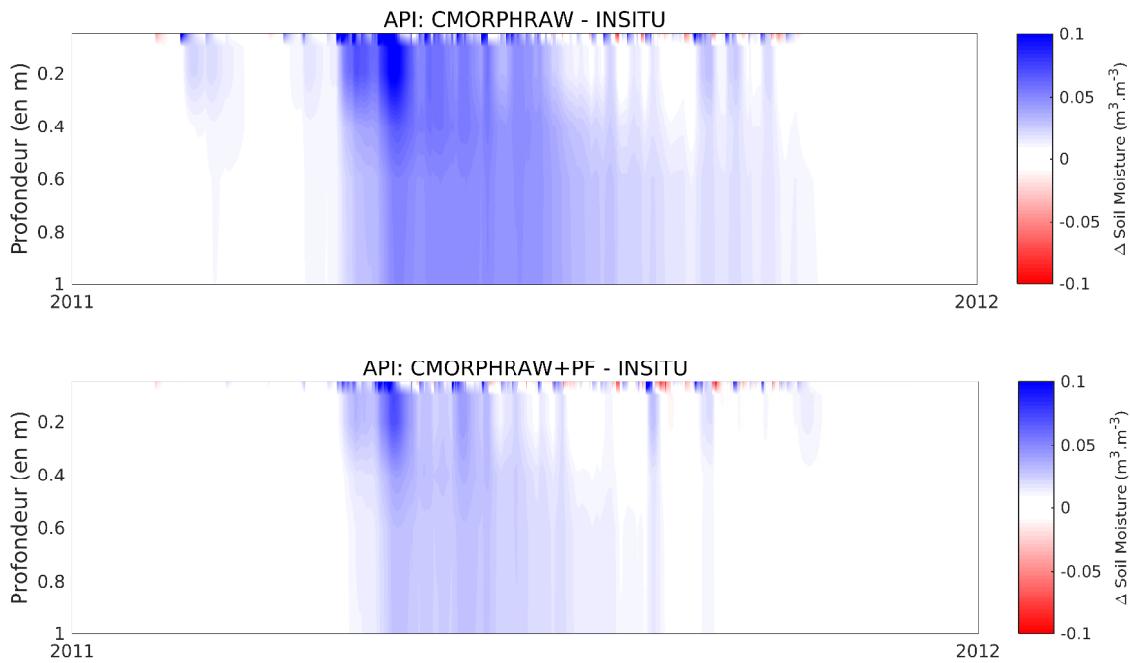


FIGURE 3.16 – Différences d'humidité du sol de 0 à 1 m, simulée par l'API, entre la simulation à partir des pluies *in-situ* et celle forcée par CMORPHRAW avant et après assimilation (figure du haut et du bas).

Afin d'étudier plus en détails l'apport de l'assimilation, analysons les profils de scores sur les Figures 3.17 et 3.18. Sur ces Figures sont représentés les scores d'humidité simulée sur la colonne de sol pour les sites du Bénin en a) et du Niger en b) par rapport aux sondes d'humidité *in-situ*. Les profils en trait noir correspondent aux scores quand le modèle est forcé avec les pluies *in-situ*. Les profils en traits pointillés de couleur sont les simulations lorsque le modèle est forcé par les produits de pluie *temps-réel* (RAW). Les profils en trait plein de couleur

### 3.5. ASSIMILATION DE SMOS EN CONTRAIGNANT LES PRÉCIPITATIONS AVEC UN FILTRE PARTICULAIRE

correspondent aux simulations forcées par le produit *ajustés* (ADJ). Les profils violets en trait plein correspondent aux simulations après assimilation de SMOS. Plus les profils de couleurs se rapprochent du profil noir, plus il se rapprochent de l'optimal de simulation. Intéressons-nous à la correction des produits TRMMRAW, Figure 3.17, et CMORPHRAW, Figure 3.18.

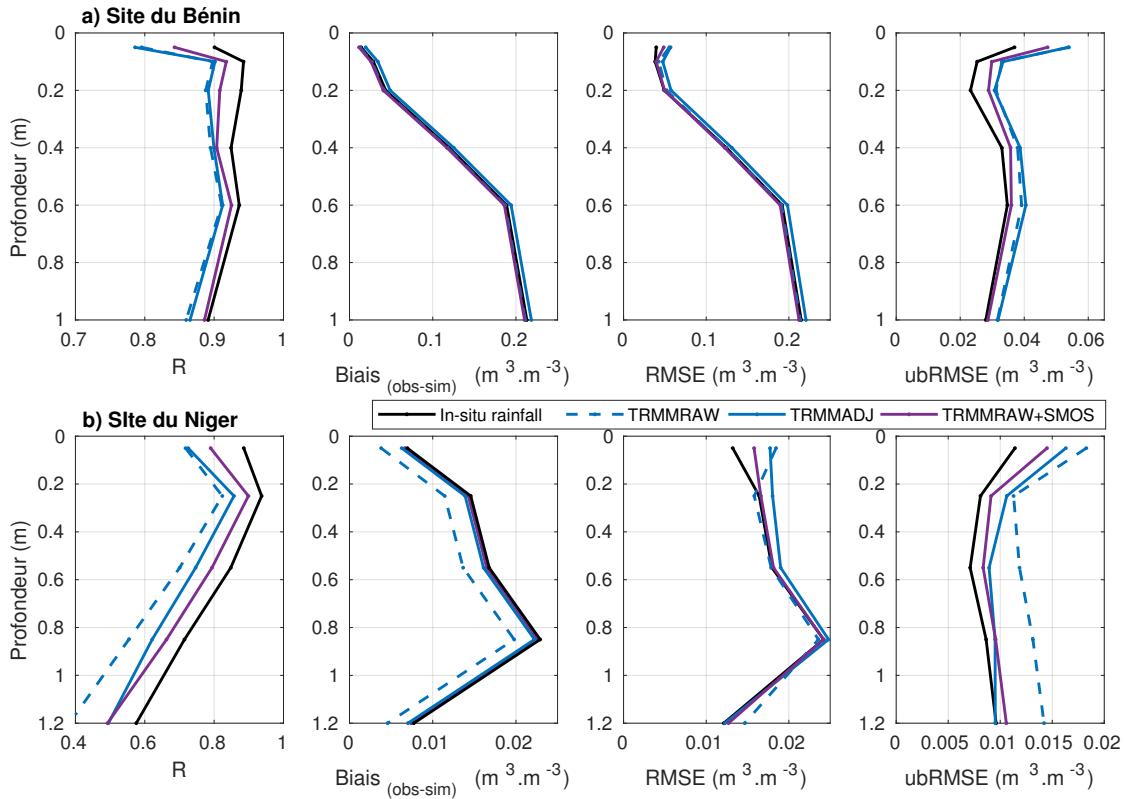


FIGURE 3.17 – Scores par profondeur entre les sondes d’humidité du sol *in-situ* et les humidités simulées par l’API avec les produits de pluies *in-situ* (trait plein noir), TRMMADJ (trait plein bleu) et TRMMRAW avant/après assimilation (trait pointillé bleu/trait plein violet).

Sur la Figure 3.17 les profils représentent les scores pour le produit TRMM.

Pour les scores de corrélation, au Bénin, les produits TRMMRAW et TRMMADJ produisent sensiblement les mêmes scores, alors que le produit TRMMRAW après assimilation (profil violet) se situe entre ces derniers et le profil de référence (en noir). Pour le Niger, les corrélations dans l’ordre décroissant : les simulations avec les produits de pluie *in-situ* (trait plein noir), puis le produit TRMMRAW assimilé, le produit TRMMADJ et enfin le produit TRMMRAW sans assimilation. Globalement l’assimilation permet une augmentation de +0.05 point de corrélation pour le site du Bénin et +0.1 pour le Niger.

Concernant le biais, il reste assez fort pour le Bénin, avec une sous-estimation de l’humidité croissante avec la profondeur. Pour le Niger, le produit TRMMRAW sans assimilation permet un biais légèrement plus faible que les autres produits.

Le RMSE, étant dépendant du biais, est donc impacté par ce dernier, analysons alors le ubRMSE. Pour le Bénin, l’assimilation (en violet) permet de se rapprocher des scores atteint par les simulations avec les pluies *in-situ*. Pour le Niger, le constat est le même, on notera cependant la forte amélioration TRMMRAW avant/après assimilation.

### 3.5. ASSIMILATION DE SMOS EN CONTRAIGNANT LES PRÉCIPITATIONS AVEC UN FILTRE PARTICULAIRE

---

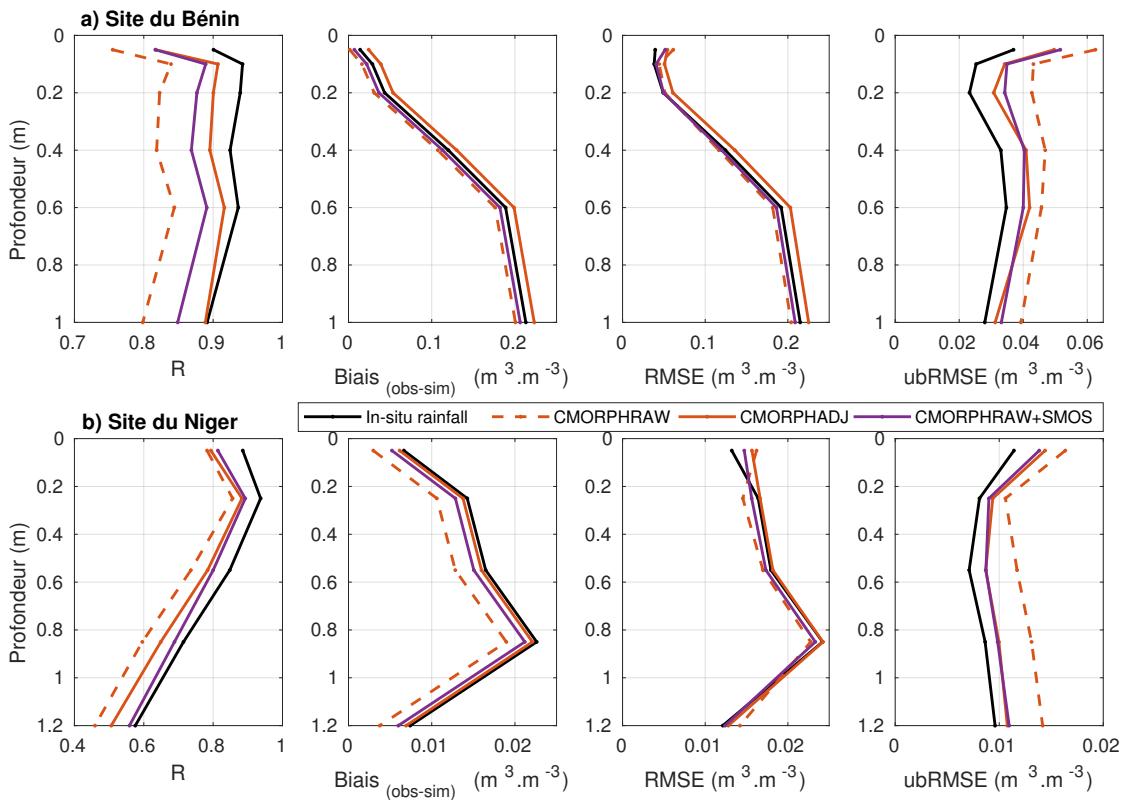


FIGURE 3.18 – Scores par profondeur entre les sondes d’humidités du sol *in-situ* et les humidités simulées par l’API avec les produits de pluies CMORPHRAW avant/après assimilation (trait plein/- pointillé).

Sur la Figure 3.18 les profils représentent les scores pour le produit CMORPH. Pour les scores de corrélation, au Bénin, on remarque que l’utilisation du produit CMORPHADJ à la place du produit CMORPHRAW améliore les corrélations de +0.1 point, et l’assimilation permet d’augmenter les corrélations de +0.05 point. Pour le site du Niger, l’assimilation permet de se rapprocher du profil noir, et ainsi d’atteindre de meilleurs scores que l’utilisation du produit CMORPHADJ. Pour le biais, les valeurs absolues sont assez fortes et limitent l’interprétation de la différence relative entre les produits, même constat pour le RMSE. Pour le ubRMSE on observe que l’assimilation du produit CMORPHRAW permet d’atteindre le même niveau que les scores lors de l’utilisation du produit *ajusté* CMORPHADJ.

### 3.5.3 Spatialisation de la méthode

Nous avons vu que l'assimilation permettait d'améliorer les simulations d'humidité sur les sites du Bénin et du Niger. L'objectif ici est de générer des cartes d'humidité du sol à partir de l'API. Intéressons-nous à la spatialisation de la méthode sur la région de l'Afrique de l'Ouest [-20 : 20 °E ; 0 : 24 °N]. Pour cela il est d'abord nécessaire de spatialiser les paramètres  $\theta_{sat}$ ,  $\theta_{res}$ ,  $\tau$ ,  $d_{soil}$  et  $T$  (nécessaire aux équations (2.7), (2.8) et (2.9)).

La limite de saturation,  $\theta_{sat}$  a été définie à  $0.45 \text{ m}^3.\text{m}^{-3}$  sur toute la zone.

L'humidité résiduelle,  $\theta_{res}$ , a été définie comme la moyenne des séries temporelles d'humidité du sol sur chaque pixel simulées avec un  $\theta_{res}=0$ . La Figure 3.19 a) représente ce paramètre. On retrouve ainsi, comme sur les séries temporelles de mesures *in-situ*,  $0.02 \text{ m}^3.\text{m}^{-3}$  pour le Niger et  $0.04 \text{ m}^3.\text{m}^{-3}$  pour le Bénin.

Le paramètre  $\tau$ , représentant le temps de ressuyage du sol, est calculé selon l'équation tirée de [Louvet et al., 2015] :

$$\tau = 32 \times \ln(clay) + 174 \quad (3.14)$$

avec *clay* issu de la carte 2.33. Cette équation permet d'ajuster le temps de ressuyage du sol en fonction du taux d'argile (plus le sol est argileux plus l'assèchement sera long et vice versa). On retrouve ce coefficient représenté carte 3.19 b).

Le  $d_{soil}$ , représentant la "capacité" du sol à stocker de l'eau, est ici calculé à partir de données de végétation (LAI). En effet, l'hypothèse est faite que plus il y a de végétation, moins le sol peut stocker de l'eau (par évapotranspiration). Ce paramètre est donc calculé comme suit :

$$d_{soil} = \begin{cases} 35 & \text{si } LAI > 1.5 \\ 75 \times LAI + 142.5 & \text{si } 0.6 > LAI > 1.5 \\ 100 & \text{si } LAI < 0.6 \end{cases} \quad (3.15)$$

La Figure 3.19 c) représente ce paramètre. On retrouve le fort gradient latitudinal et la bande de transition sahélienne.

Ainsi, à partir de ces paramètres spatialisés, il est possible de calculer l'humidité du sol à partir de l'API sur l'Afrique de l'Ouest. La Figure 3.19 d) représente la moyenne de l'humidité à 5 cm sur l'année 2002 lorsque le modèle est forcé par CMORPHRAW. Précédemment nous avons vu que la méthode d'assimilation par filtre particulier permettait de réduire les incertitudes sur ce type de produit de pluie satellite *temps-réel*. Analysons alors l'apport spatiale de l'assimilation, Figure 3.20.

### 3.5. ASSIMILATION DE SMOS EN CONTRAIGNANT LES PRÉCIPITATIONS AVEC UN FILTRE PARTICULAIRE

---

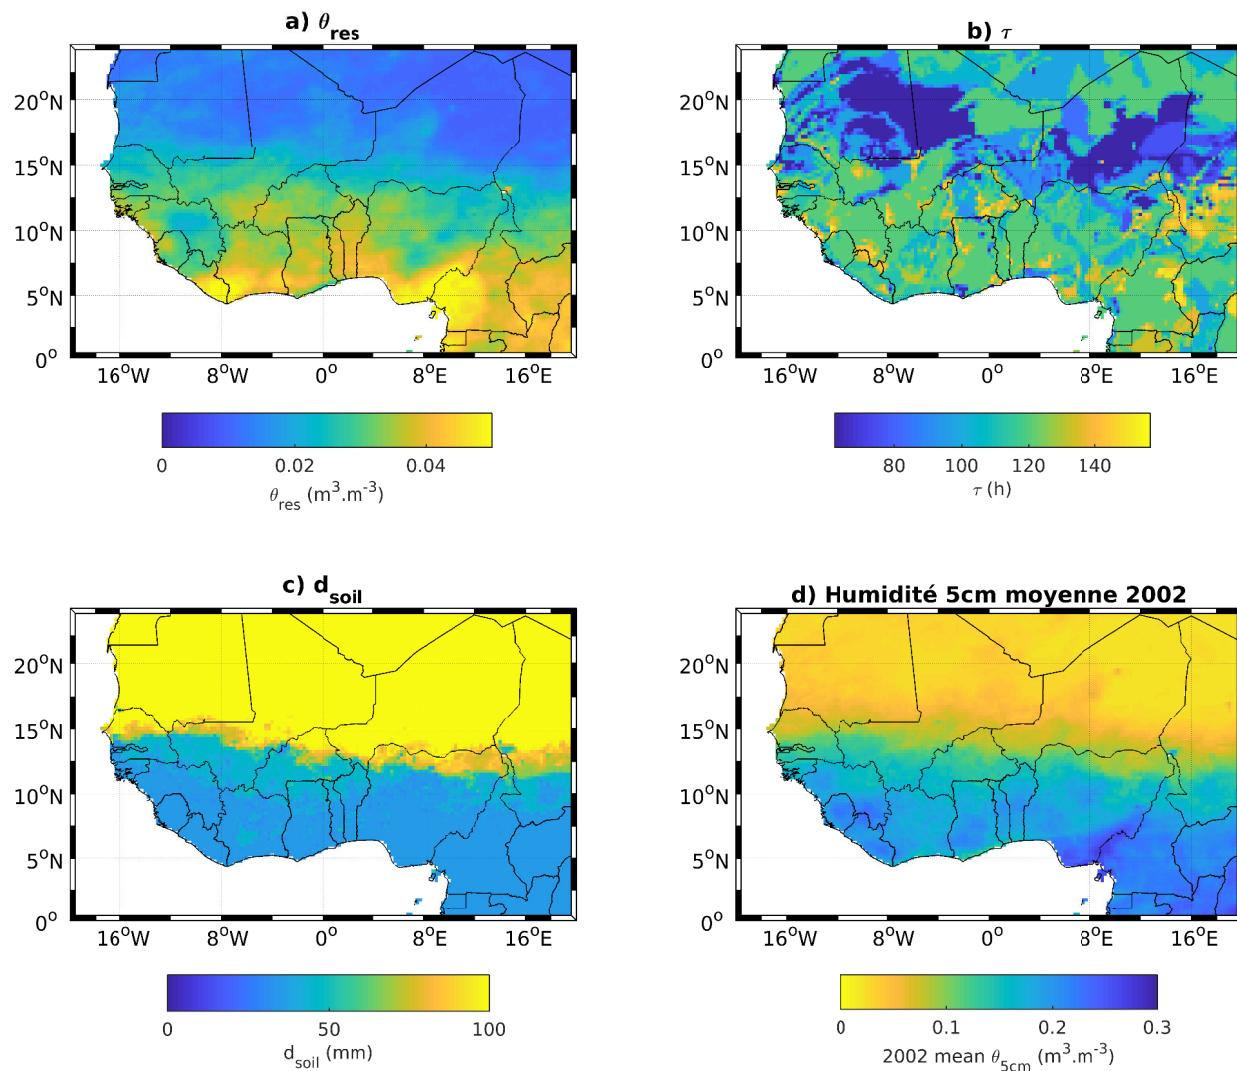


FIGURE 3.19 – Spatialisation des paramètres  $\theta_{res}$  en a),  $\tau$  en b),  $d_{soil}$  en c) et exemple d'humidité moyenne simulée en d).

### 3.5. ASSIMILATION DE SMOS EN CONTRAIGNANT LES PRÉCIPITATIONS AVEC UN FILTRE PARTICULAIRE

Sur la Figure 3.20 sont représentés en a) la trace SMOS, en b) le modèle API sans assimilation, et en c), après assimilation pour le 13 Août 2011 à 18h. On remarque alors que les *patterns* d'humidité mesurés par SMOS, en a), se retrouvent bien sur la simulation après assimilation, en c).

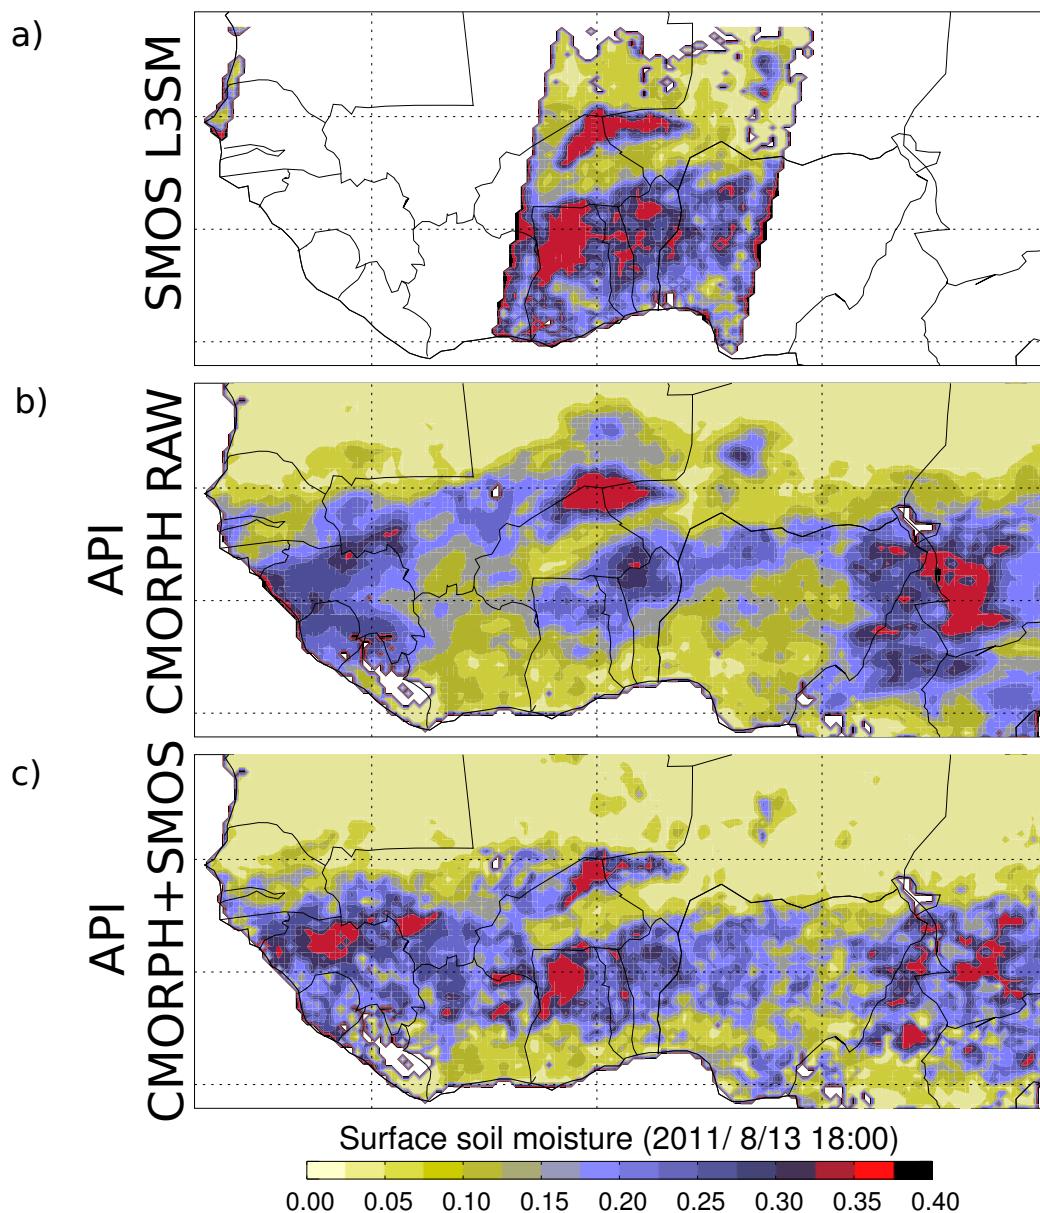


FIGURE 3.20 – Évaluation de l'impact spatial de l'assimilation de la trace SMOS (en a)), dans l'API avant assimilation (en b)) et après assimilation (en c)).

## 3.6 Résumé et conclusion

Dans ce chapitre, nous avons vu comment intégrer SMOS dans un modèle de surface de manière à profiter à la fois de la mesure d'humidité SMOS et de la possibilité d'atteindre l'humidité en zone racinaire au travers la modélisation.

Dans un premier temps nous avons observé les limites de l'utilisation du Simplified Extended Kalman Filter dans SURFEX pour améliorer la représentation de l'humidité du sol. En effet, dans ce cas-ci les erreurs proviennent principalement des forçages de précipitations, or ce filtre ne prend pas en compte les erreurs de forçage. De plus, le filtre à une forte sensibilité aux erreurs des observations, qui sont relativement compliquées à quantifier. De plus la non-linéarité du modèle, ainsi que l'ajout/retrait d'eau pendant la saison sèche générée par le bruit SMOS, dégrade les séries temporelles.

Dans un second temps, l'implémentation d'un Filtre Particulaire s'est montrée relativement efficace pour modifier les précipitations afin d'améliorer les humidités du sol simulées. En effet, les évaluations des humidités du sol simulées sur les deux sites, du Bénin et du Niger, ont montré que l'assimilation de SMOS permettait d'améliorer considérablement les humidités du sol modélisées à partir de forçage de pluie *temps-réel* (Raw). Pour les deux sites, et pour les produits CMORPH et TRMM, le schéma d'assimilation permet d'atteindre des scores au minimum égaux à ceux obtenus avec le produit *ajusté*, mais avec celui *temps-réel*. C'est un point important car il signifie que le temps d'attente de plusieurs mois avant d'avoir les produits *ajustés* par les pluviomètres peut être réduit à quelques heures.



### Prochain chapitre

Dans ce chapitre nous avons vu comment assimiler des observations SMOS dans les modèles de surface de manière à générer des cartes d'humidité du sol en superficie et en profondeur en *temps-réel*. Maintenant, intéressons-nous à l'interprétation de ces cartes avec une étude sur les anomalies de rendement de mil en Afrique de l'Ouest.

# Chapitre 4

## Suivi des rendements agricoles en Afrique de l'Ouest à partir de données d'humidité du sol

---

4.1	Introduction	96
4.2	Zone d'étude	97
4.3	Méthode	98
4.4	Étude à l'échelle locale	99
4.4.1	Données de rendements	99
4.4.2	Données d'humidité du sol	100
4.4.3	Relation à l'échelle locale	101
4.5	Étude à l'échelle nationale	105
4.5.1	Données de rendements	105
4.5.2	Données d'humidité du sol	105
4.5.3	Analyse de la variabilité temporelle	106
4.5.4	Analyse de la variabilité spatiale	108
4.6	Étude à l'échelle régionale	110
4.6.1	Relation à l'échelle de la bande sahélienne	110
4.6.2	Vers des cartes de rendement ?	113
4.7	Résumé et conclusion	115

---

Ce chapitre fait lieu d'un article en *review* dans : *Journal of Agricultural and Forest Meteorology* sous la référence :

F. Gibon, T. Pellarin, C. Román-Cascón, A. Alhassane, S. Traoré, Y. Kerr, D. Lo Seen, C. Baron, *Millet yield estimations in Sahel using satellite-derived soil moisture time series*, 2017, Agricultural and Forest Meteorology.

## 4.1 Introduction

L'état hydrique du sol est l'un des facteurs essentiels de la croissance des plantes. Le stress généré par un manque d'eau sur les cultures céréaliers agit sur le rendement (et génère donc potentiellement de fortes conséquences socio-économiques). Dans certaines régions où l'irrigation est monnaie courante, ce souci est compensé par l'apport artificiel d'eau (irrigation). Cependant, comme le montre la carte de la FAO Figure 4.1, la proportion de zones irriguées est relativement faible dans la partie orientale de l'Afrique de l'Ouest ; la surface de zones cultivées irriguées y représente en effet moins de 1%. Or, dans ces régions, la population est très dépendante des productions agricoles, de par la pratique majoritaire d'une agriculture de subsistance mais aussi d'un point de vue économique.

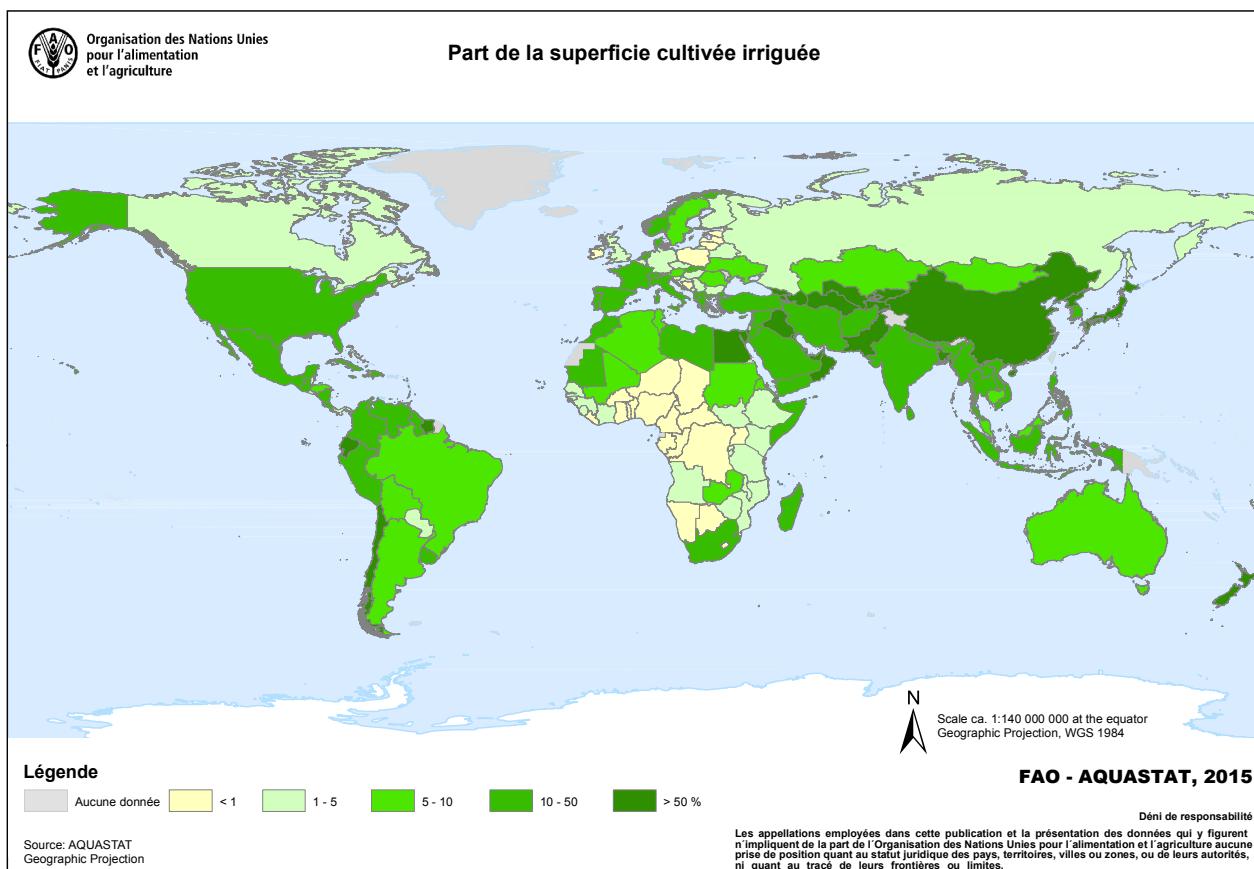


FIGURE 4.1 – Répartition des parts irriguées des surfaces cultivées.

Dans ce chapitre, nous allons étudier le potentiel des mesures de l'humidité du sol pour fournir des informations sur le rendement des cultures de mil au Niger. La première partie contient une description des liens statistiques entre le rendement des cultures mesuré *in-situ* et les mesures *in-situ* de l'humidité du sol sur diverses périodes temporelles et différentes profondeurs du sol. Dans la seconde partie, les cartes d'humidité du sol obtenues au chapitre précédent sont utilisées pour tenter d'estimer les variations de rendement du mil à grande échelle. L'évaluation de la méthode est effectuée en utilisant les informations sur les rendements du mil fournies par la FAO de 1998 à 2014.

## 4.2 Zone d'étude

La zone d'étude est située au Niger, pays du Sahel, en Afrique de l'Ouest. La majeure partie de la population est concentrée dans la partie sud du pays, qui concentre également la majorité des zones agricoles. Le régime de précipitations est contrôlé par la mousson de l'Afrique de l'Ouest avec une mono-modalité annuelle générant une saison sèche et une saison des pluies (de juin à octobre). Avec une température moyenne annuelle de 29 °C, le Niger est connu comme l'un des endroits les plus chauds de la Terre. Principalement basé sur une agriculture pluviale (moins de 1% de la superficie est irriguée), la variabilité des précipitations (spatiale et temporelle) affecte fortement la production agricole. La production de mil, principalement située au sud (voir Figure 4.2), est la principale culture de subsistance du Niger ; le mil représente ~47% de la production céréalière des pays du Sahel [[Ouendeba and Siaka Sogoba, 2004](#)]).

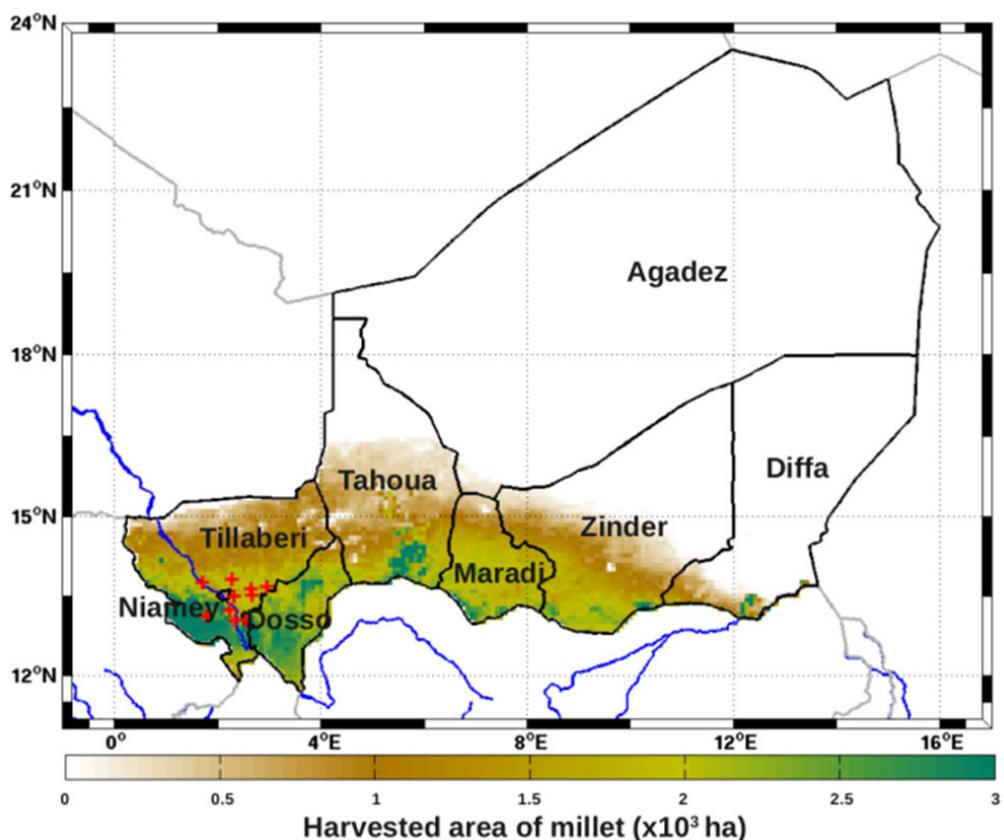


FIGURE 4.2 – Répartition des surfaces de cultures de mil (zones colorées) fournie par la FAO Global Agro-Ecological Zone (GAEZ). Les croix rouges autour de Niamey sont les 10 villages dont les données de rendements sont utilisées dans cette étude

La région autour de Niamey (appelée Degré Carré de Niamey) a été largement instrumentée lors de l'expérience scientifique AMMA (African Monsoon Multidisciplinary Analysis) ([\[Redelsperger et al., 2006\]](#), [\[Lebel et al., 2009\]](#)). De nombreuses installations de mesures hydrologiques, météorologiques et biologiques y ont été établies en 2005 et sont aujourd'hui gérées par l'Observatoire AMMA-CATCH. En parallèle, des mesures de rendement de cultures ont été effectuées à divers endroits (10 villages, les croix rouges 4.2), et fournies par le CIRAD et le Centre régional AGRHYMET à Niamey.

Un zoom sur la zone autour de Niamey est fait sur la Figure 4.3. Sur cette figure on peut y retrouver les 10 villages, autour de Niamey (x sur la carte), pour lesquels les rendements de mil sont suivis (+ et noms du village dans la légende). On retrouve les sondes d'humidité (◇) et les pluviomètres (○) utilisés dans l'étude.

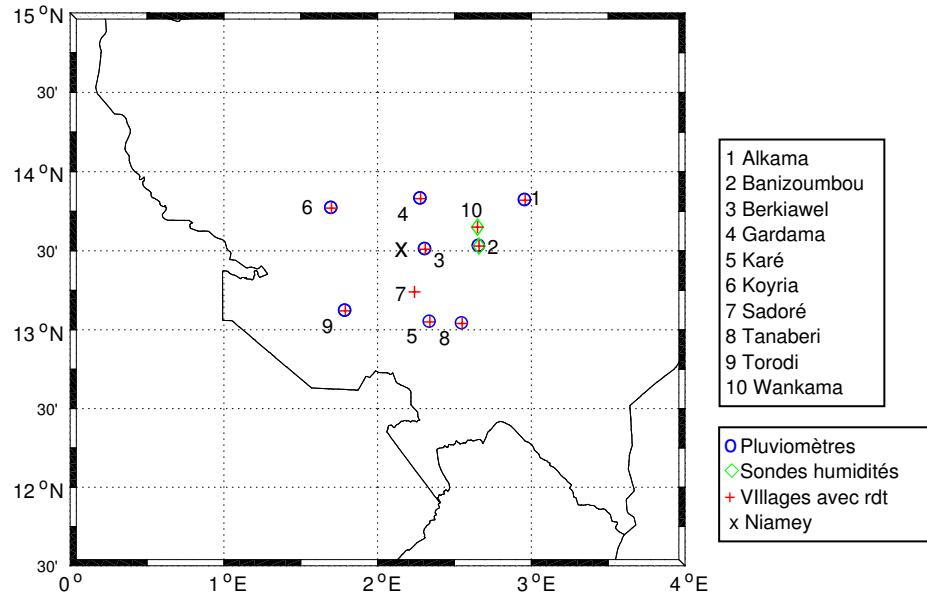


FIGURE 4.3 – Répartition des villages où le suivi des rendement de mil est effectué (croix rouges), des sondes d'humidité (losanges verts) et des pluviomètres (ronds bleus).

### 4.3 Méthode

Les besoins en eau ne sont pas les mêmes en fonction des différentes périodes de la phénologie de la plante ([Mahalakshmi et al., 1987], [Eldin, 1990]). Afin d'évaluer l'impact temporel des diverses périodes, nous avons effectué une analyse basée sur la corrélation entre l'humidité du sol et le rendement annuel du mil, selon une fenêtre temporelle glissante et à durée variable.

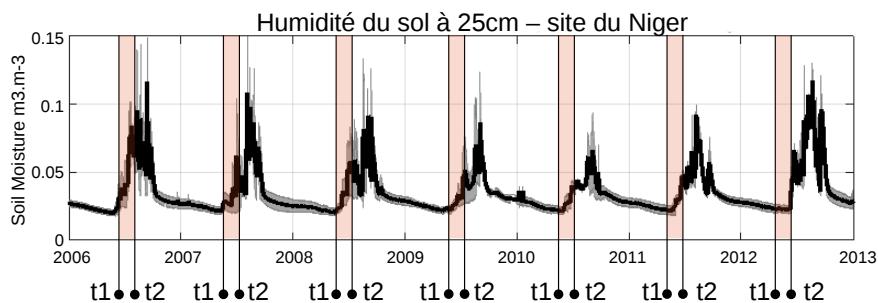


FIGURE 4.4 – Afin de calculer la relation entre humidité du sol et rendement, les anomalies ont été calculées pour chaque jeu de dates ( $t_1 : t_2$ ), zone rouge sur les séries temporelles.

La Figure 4.4 présente une série d'humidité avec une durée sélectionnée entre  $t_1$  et  $t_2$ . Les dates  $t_1$  et  $t_2$  sont les mêmes pour les années 2006 à 2012. Les anomalies calculées  $SM_{\text{anomalie}}$

sont rapportées ici en deux étapes. D'abord la moyenne de l'humidité  $SM_{periode}(y)$  est calculée pour toutes les années  $y$  dans la période entre  $t1$  et  $t2$  :

$$SM_{periode}(y) = \frac{1}{nt} \sum_{n=t1}^{t2} SM(n, y) \quad (4.1)$$

avec  $nt$  le nombre de points entre les périodes  $t1$  et  $t2$ .

Afin d'évaluer les différences notables dues à la climatologie, l'anomalie est alors calculée, définie comme étant la différence à la moyenne :

$$SM_{anomalie}(y) = SM_{periode}(y) - \frac{1}{ny} \sum_{y=y1}^{y2} SM_{periode}(y) \quad (4.2)$$

avec  $ny$  le nombre d'années entre les années  $y1$  et  $y2$ .

## 4.4 Étude à l'échelle locale

### 4.4.1 Données de rendements

Dans cette première partie, une étude locale est effectuée à l'échelle des villages. Les données de rendement de mil sont obtenues à partir de prélèvements effectués dans 10 villages autour de Niamey (croix rouges sur la Figure 4.2). Le protocole utilisé est le suivi d'une cinquantaine de parcelles agricoles pour chaque village, de 2004 à 2012 (total de plus de 500 parcelles chaque année). Pour surveiller ces parcelles, trois placettes expérimentales ( $\sim 5 \times 5$  m) ont été suivies en pesant, après séchage, la quantité de mil récolté à l'intérieur. Puis, la quantité de grain a été normalisée par la surface pour retrouver le rendement en kg/ha. Une description détaillée de l'ensemble de ces données se trouve dans [Marteau et al., 2011].

Sur la Figure 4.5 sont représentés les rendements de chaque parcelle du village de Wankama en 2012. On observe alors une assez forte variabilité car les valeurs vont de 215 kg/ha pour la parcelle 25 jusqu'à 1050 kg/ha pour la parcelle 39.

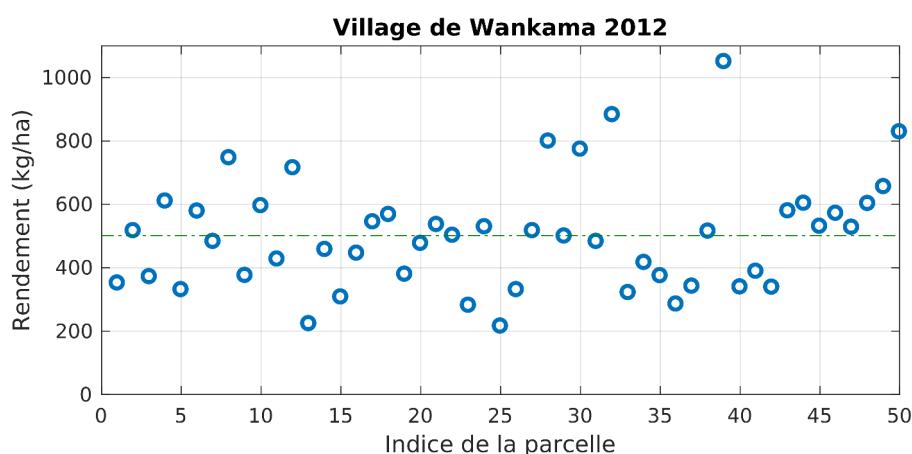


FIGURE 4.5 – Rendements de l'ensemble des parcelles du village de Wankama en 2012, avec en pointillé vert, la moyenne.

Devant cette forte variabilité, une moyenne est effectuée (donc 502 kg/ha en 2012 pour Wankama, trait pointillé vert sur Figure 4.5) afin d'obtenir des variabilités entre les villages, voir Figure 4.6.

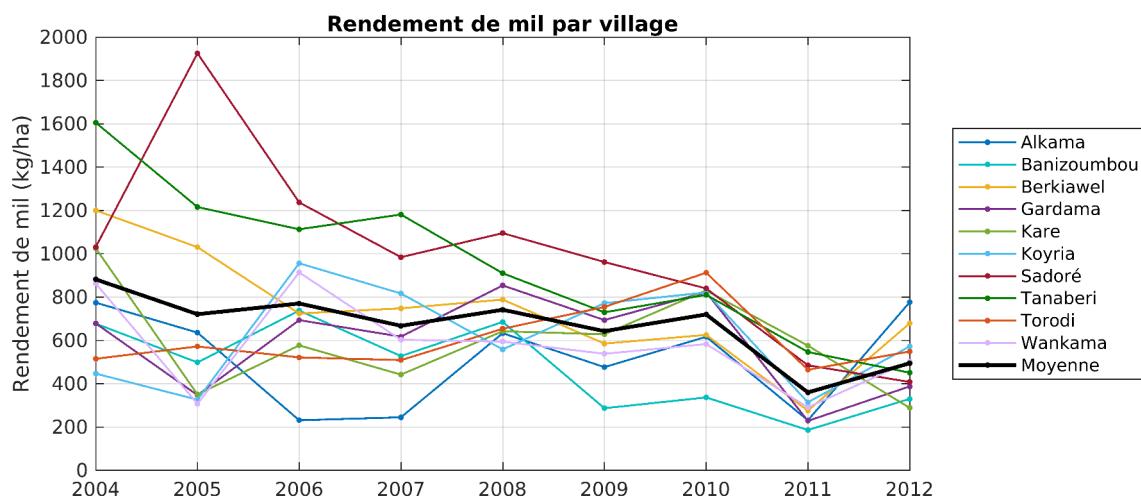


FIGURE 4.6 – Évolution des rendements de mil des 10 villages autour de la région de Niamey (voir croix rouges carte 4.2).

Sur la Figure 4.6 on observe les variations de rendements pour les années 2004 à 2012 pour les 10 villages présentés sur la carte 4.3. Ces derniers ont une assez grande variation entre les villages. Par exemple, en 2007, Alkama présente un rendement de 244.5 kg/ha alors que Tanabéri atteint les 1180 kg/ha. Cela peut être partiellement expliqué par les différences latitudinales entre les villages. En effet, les villages de Karé, Tanabéri, Torodi et Sadoré sont situés au Sud du domaine d'étude où le cumul de précipitation annuel est compris entre 500 et 700 mm/an alors que pour les autres villages il est compris entre 300 et 500 mm/an.

Le rendement moyen des 10 villages de 2004 à 2012, en noir est de 680 kg/ha, ce qui est assez faible par rapport au rendement de mil obtenu dans les expérimentations en environnement contrôlées (où l'apport en eau n'est pas facteur limitant). Cependant, cette valeur est courante au Niger (souvent avec maximum de 1250 kg/ha, [Rockström, 1999] et généralement inférieure à 1000 kg/ha [JAICAF, 2009]) en raison de la quasi absence d'intrants, d'engrais et d'irrigation.

#### 4.4.2 Données d'humidité du sol

Les données d'humidité utilisées sont issues des mesures *in-situ*, comme le montre le profil 4.7 pour le site de Wankama.

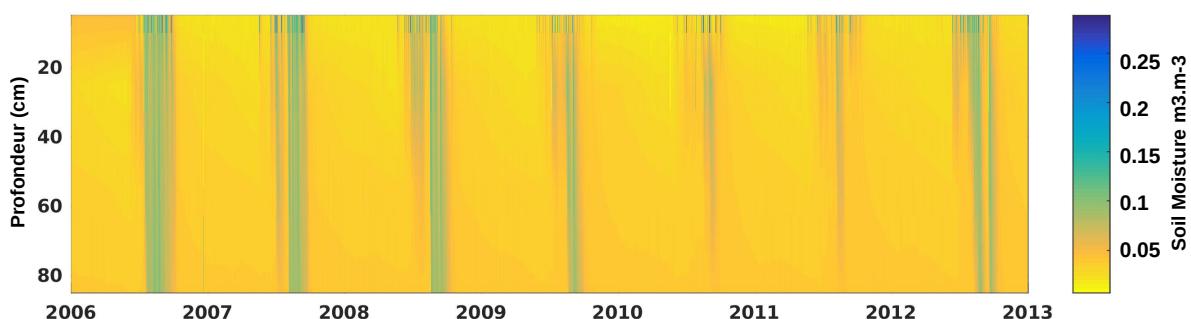


FIGURE 4.7 – Profils d'humidité du sol obtenus à partir des sondes de Wankama au Niger pour les années 2006–2012.

Comme il n'y a pas au moins une sonde pour chaque village, les variations d'humidité pour chacun des villages ont été estimées à l'aide des pluviomètres AMMA-CATCH disponibles dans 8 des 10 villages. Pour cela le modèle API (voir Partie 2.5.2) a été forcé avec les pluies correspondantes. Pour Sadoré, il n'y a pas de pluviomètre, et pour Wankama c'est le pluviomètre de Banizoumbou qui est utilisé. On peut ainsi dériver des chroniques d'humidité pour 9 des 10 villages.

#### 4.4.3 Relation à l'échelle locale

Le lien potentiel entre humidité du sol et rendement de mil est étudié à l'échelle locale. Dans un premier temps intéressons-nous à l'analyse des données de mesure d'humidité du sol *in-situ* (voir Figure 4.7) et à leur potentiel pour expliquer les variations de rendements du village de Wankama.

La Figure 4.8 représente les corrélations entre anomalies d'humidité du sol à 4 profondeurs différentes (5, 25, 55 et 85 cm) et anomalies de rendement pour les années 2006 à 2012. La fenêtre d'analyse ( $t_1 : t_2$  dans la partie Méthode) a été définie de 5 à 40 jours (correspondant à chacune des figures). La partie plus épaisse des courbes correspond à des corrélations  $R^2$  avec des p-value inférieures à 0.1.

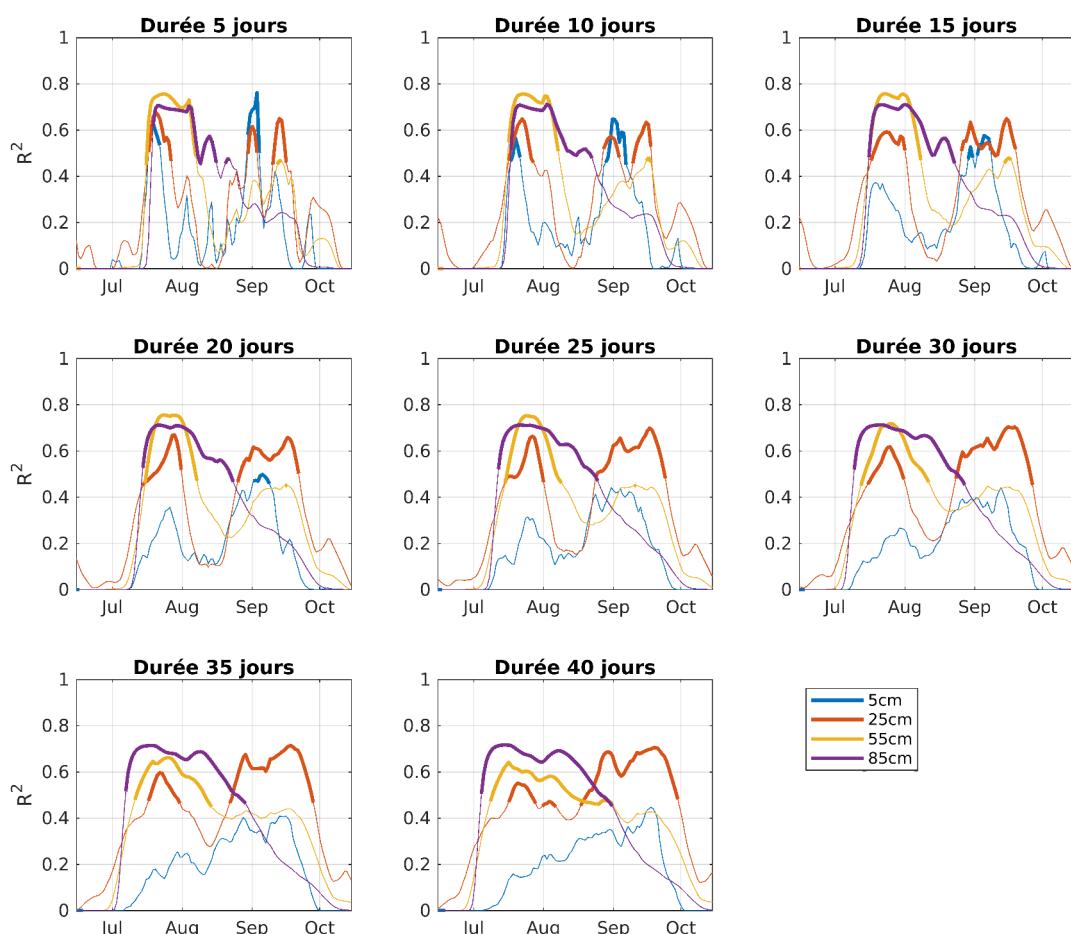


FIGURE 4.8 – Analyse de la corrélation entre les anomalies de rendement et les anomalies d'humidité du sol à 5, 25, 55 et 85 cm pour des fenêtres d'analyse de 5 à 40 jours.

Une analyse globale des figures montre que la variabilité est forte avec une fenêtre de 5 jours, puis s'adoucit en fonction de la durée de la fenêtre. On observe globalement 2 "lobes",

un premier situé à la fin du mois de juillet et l'autre centré sur le début du mois de septembre. L'analyse de la Figure 4.8 montre différentes informations. Tout d'abord, intéressons-nous au signal à 5 cm (en bleu). Ce dernier semble montrer un signal assez fort,  $R^2=0.78$  du 1<sup>er</sup> au 6 septembre (fenêtre de 5 jours). Cela signifie que les anomalies d'humidité à 5 cm pendant cette période représentent 78% de la variation de rendement sur les 7 années. Cependant, la courte durée, de 5 jours, combinée au faible nombre de points analysés, ne rend pas ce signal fortement significatif. On observe ensuite que les lobes bleus diminuent au fur et à mesure que la fenêtre choisie est grande. Cela peut être interprété par le fait que l'humidité de surface connaît une grande dynamique temporelle, et qu'elle n'est pas forcément représentative de l'humidité disponible pour les racines des plantes.

Les courbes à 25 cm montrent des corrélations significatives à chaque fois pour les 2 périodes identifiées précédemment, à environ  $R^2=0.6$  et ce quelle que soit la taille de la fenêtre. Cela signifie que les anomalies d'humidité pendant ces périodes, à 25 cm de profondeur, semblent impacter les rendements.

Pour les profondeurs de 55 et 85 cm, un lobe principal, toujours fin juillet, montre un signal assez fort. Ce dernier peut être interprété comme étant l'anomalie du front d'humectation de l'eau dans la colonne de sol. En effet, la disponibilité de l'eau dans la zone racinaire est fortement dépendante du début de saison des pluies. Un fort début de saison des pluies permet l'infiltration de l'eau dans le sol beaucoup plus rapidement en profondeur, impactant donc l'eau disponible pour les cultures.

L'évolution bimodale de la corrélation, qui montre une période critique en juillet puis une deuxième période d'importance en septembre peut être aussi interprétée d'un point de vue de la phénologie du mil. Ces deux périodes correspondent respectivement à la période de «remplissage du grain» (de mi-août à fin septembre) et à la période «reproductive» (juillet) de la culture du mil. Au cours de la première période (juillet), de bonnes conditions de croissance du mil sont associées à un grand nombre de grains, tandis que pendant la deuxième période (septembre), de bonnes conditions de disponibilité en eau mènent à une augmentation rapide du poids des grains. Ces résultats confirment que la disponibilité de l'eau joue un rôle important au cours de ces deux périodes-clés et est conforme à la phénologie du mil dans cette région. Enfin, le coefficient de corrélation plus élevé obtenu à une profondeur de 25 cm est probablement dû à la distribution des racines du mil, qui sont principalement concentrées (90%) dans les 80 cm supérieur du profil du sol ([[Rockström and De Rouw, 1997](#)] bien que certaines racines aient été observées jusqu'à une profondeur de 240 cm dans cette étude).

La variabilité de rendement entre les villages étant assez importante, voir Figure 4.6, analysons leurs représentations respectives à l'aide des humidités simulées à 30 cm, à partir de l'API. Comme vu précédemment, sur la Figure 2.41, les simulations de l'humidité du sol sont de bonne qualité jusqu'à 50 cm lorsque les pluies utilisées sont issues de pluviomètres. Dans notre étude, des pluviomètres sont installés dans chacun des villages, permettant ainsi de simuler les humidités à 30 cm pour chacun des villages, et pour les années 2004–2012.

La Figure 4.9 représente les séries d'humidités simulées pour chacun des villages en bleu, et les rendements respectifs en rouge. On remarque une certaine cohérence entre l'allure globale de l'humidité et l'évolution des rendements. Par exemple, on remarque une chute d'environ 50% des rendements pour les années 2009, 2010, 2011 et 2012 à Banizoumbou, qui sont sensiblement des années plus sèches que les autres. Le constat est le même pour le village de Berkiawel.

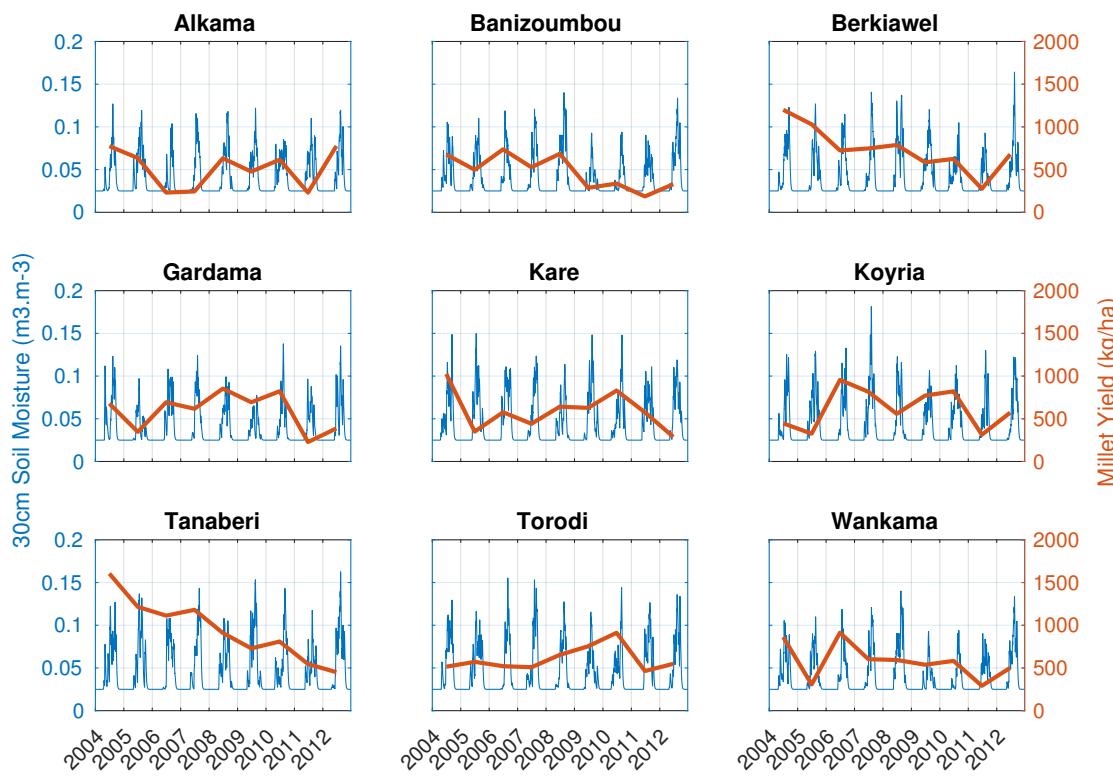


FIGURE 4.9 – Modélisation de l'humidité du sol à 30 cm à partir de l'API forcée par les pluviomètres AMMA-Catch Niger pour les années 2006–2012 et pour les 9 villages (pas de pluviomètres pour Sadoré).

Sur la Figure 4.10, on peut voir l'ensemble des humidités à 30 cm simulées pour les 10 villages avec la moyenne (courbe noire).

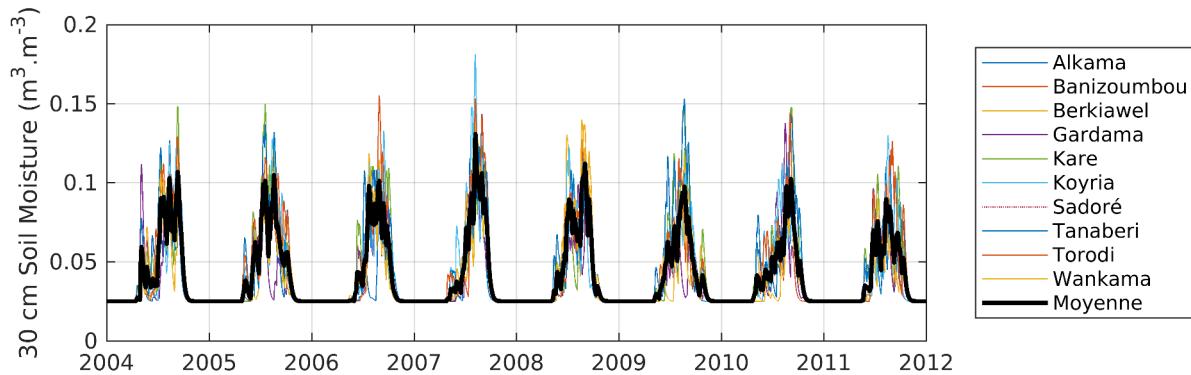


FIGURE 4.10 – Simulation de l'humidité à 30 cm pour chacun des villages à partir de l'API et des pluviomètres correspondant.

En analysant pour chaque village les corrélations entre ces données et les anomalies de rendement, on obtient la courbe 4.11. Sur la Figure 4.11 on retrouve, pour chacun des villages, les 2 périodes identifiées précédemment, c'est-à-dire juillet et début septembre (sauf pour Alkama et Torodi). Cependant, les corrélations sont plus faibles et les périodes légèrement décalées entre les villages. Ce décalage semble corrélé à la position des villages, spécifiquement à leur latitude. On remarque aussi que certains villages ne présentent qu'un seul des lobes.

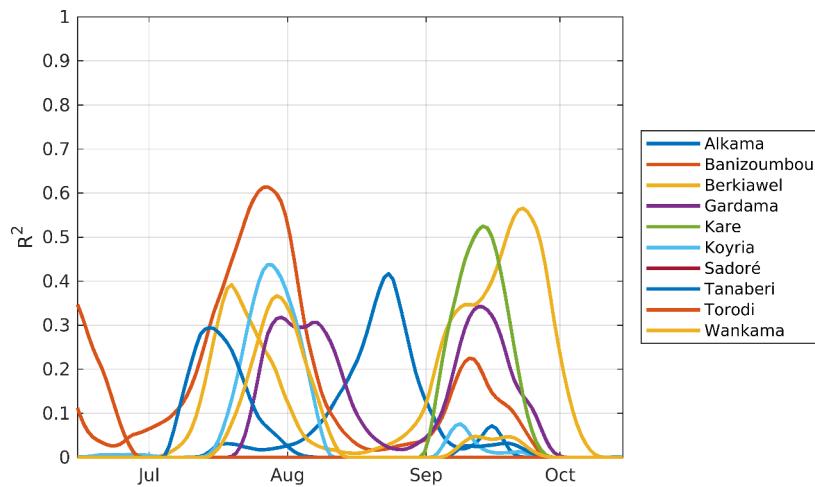


FIGURE 4.11 – Fenêtre glissante de 20 jours des corrélations entre les humidités du sol simulées à 30 cm pour chaque village et les rendements respectifs.

En analysant la moyenne des humidités et la moyenne des rendements pour les 9 villages (pas de données d'humidité pour Sadoré), on obtient la Figure 4.12 :

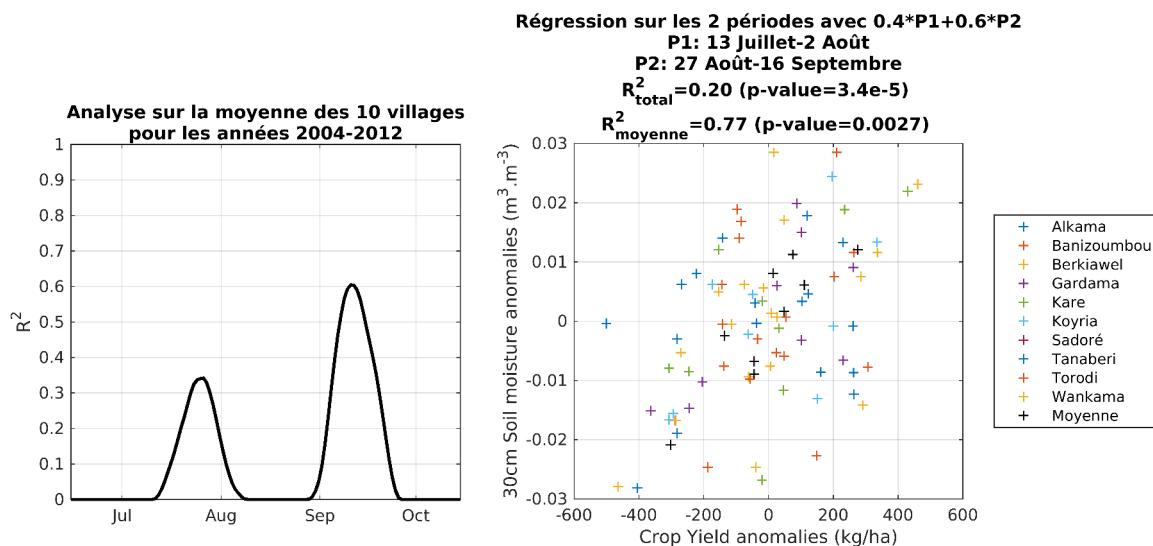


FIGURE 4.12 – A gauche, fenêtre glissante de 20 jours des corrélations entre la moyenne des humidités du sol simulées à 30 cm pour la moyenne des villages et la moyenne de rendements de villages, à droite, régression village par village (en couleur) et moyenne (en noir).

Sur la Figure 4.12, on retrouve l'analyse avec fenêtre glissante sur 20 jours. La figure montre très nettement les 2 lobes avec un ratio de 40% pour le mois de juillet et de 60% pour le mois de septembre. En analysant donc les anomalies d'humidité du sol pendant 20 jours, centrées sur le 23 juillet et 20 jours centrées sur le 6 septembre, avec un rapport 0.4 et 0.6, on obtient le nuage de points présenté sur la Figure 4.12. Sur ce graphique, l'axe des abscisses représente les anomalies de rendements pour tous les villages, et l'axe des ordonnées les anomalies d'humidité du sol à 30 cm pendant les 2 périodes, pondérées par les poids définis précédemment. On peut observer une assez forte dispersion des points de couleurs, correspondant à chacun des villages ( $R^2=0.20$ ). Lorsque l'on considère la moyenne des 9 villages en terme d'humidité et de rendement, on obtient alors les points noirs avec un  $R^2=0.77$ .

## 4.5 Étude à l'échelle nationale

### 4.5.1 Données de rendements

Le deuxième ensemble de données est fourni par le département statistique de l'Organisation des Nations Unies pour l'alimentation et l'agriculture (FAOSTAT) qui collecte des informations relatives à l'agriculture dans la plupart des pays du monde. Les données sont issues d'enquêtes annuelles soumises aux gouvernements, qui contiennent des statistiques sur la superficie et la production récoltée pour le grain sec. La répartition spatiale des zones de production de mil au Niger est illustrée Figure 4.2 et se situe principalement dans la partie sud-ouest du Niger. Cette carte résulte de la fusion de plusieurs ensembles de données d'occupation du sol : (i) la carte Global Land Cover GLC2000, (ii) une autre compilée par l'IFPRI en fonction de la Base de données sur les caractéristiques de couverture du territoire mondial (GLCC) et (iii) une couche supplémentaire de l'évaluation des ressources forestières par la FAO. Elle représente la superficie des cultures de mil l'année 2000.

Sur la Figure 4.13 on peut voir l'évolution des données de rendements de mil fournies par la FAO pour le Niger pour les années 1998 à 2014 (en trait plein noir). Les données par districts administratifs, en couleur, sont issues de CountrySTAT (division de la FAO). On remarque alors une variabilité assez inégale entre les districts au cours du temps.

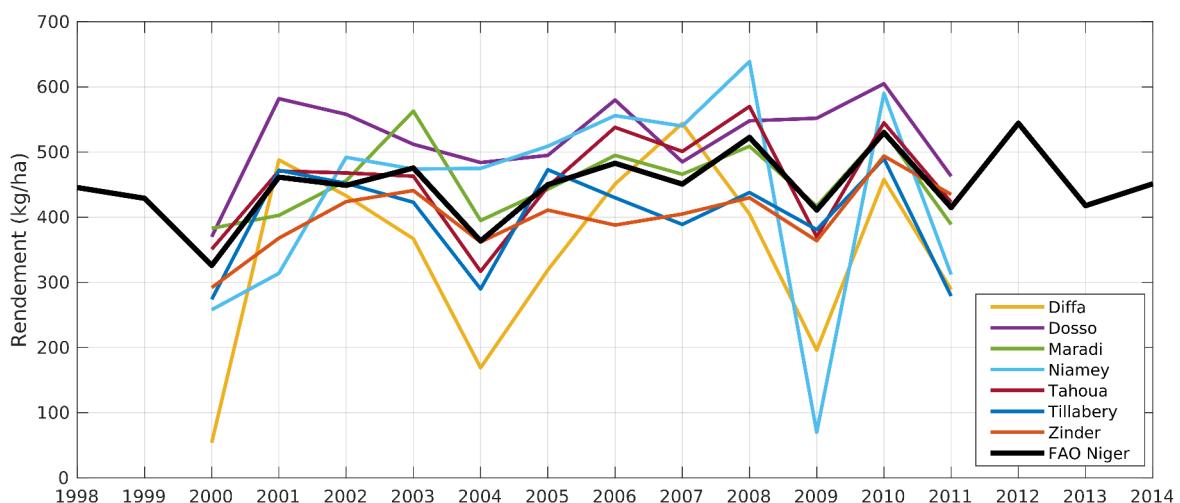


FIGURE 4.13 – Évolution des rendements de mil données par la FAO pour le Niger et ses 7 districts pour les années 1998–2014.

### 4.5.2 Données d'humidité du sol

Afin d'étudier les variations de rendement de mil face aux variations d'humidité à l'échelle régionale, des cartes d'humidité du sol ont été dérivées de l'API avec le filtre exponentiel présenté dans la Partie 2.5.2. Les cartes ont été obtenues en 2 étapes : tout d'abord des cartes d'humidité en surface  $\theta_{(t)}^{5cm}$  sont dérivées de l'équation (2.7) avec le produit CMORPHADJ. Puis, à partir de  $\theta_{(t)}^{5cm}$ , l'humidité à 30 cm de profondeur,  $\theta_{(t)}^{30cm}$ , est ensuite calculée à partir de l'équation (2.8). La Figure 4.14 représente les cartes de moyenne annuelle d'humidité du sol à 30 cm.

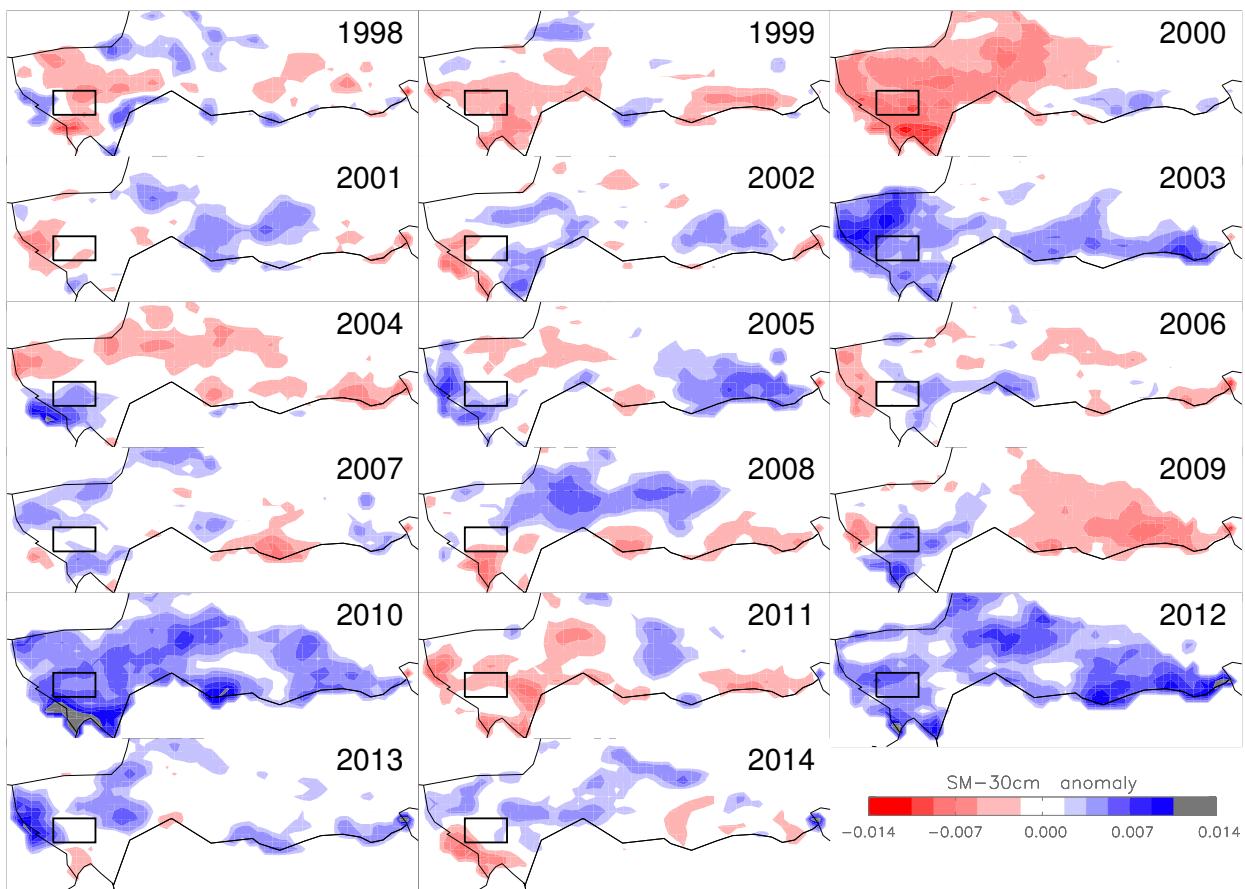


FIGURE 4.14 – Cartes d'anomalies annuelles d'humidité à 30 cm,  $\theta_{(t)}^{30\text{cm}}$ , pendant les années 1998–2014. Le carré noir est la zone autour de Niamey analysée dans l'étude locale.

#### 4.5.3 Analyse de la variabilité temporelle

Intéressons-nous à l'aspect temporel des anomalies d'humidité du sol à l'échelle du Niger. Pour cela nous allons utiliser les cartes d'humidité à 30 cm pour étudier l'impact de ces variations inter-annuelles sur les rendements de mil fournis par la FAO (données disponibles depuis 1961).

Afin d'estimer l'humidité sur la zone de culture de mil, les cartes d'humidité ont été masquées avec la zone de mil (Figure 4.2). De ces cartes "masquées", la moyenne spatiale a été calculée à chaque pas de temps (3h) afin d'obtenir une série temporelle sur 17 ans. Cette série temporelle est représentée Figure 4.15 avec, pour chaque année, la climatologie sur les 17 ans (courbe noire), et, superposées, les anomalies positives coloriées en vert et négatives en rouge.

L'analyse temporelle de l'humidité du sol à 30 cm dans toute la zone permet d'identifier les anomalies de la saison des pluies (démarrage tardif, pauses, fin précoce, ...). Ces anomalies sont importantes car elles ont un impact sur les rendements de mil ([Rockström and De Rouw, 1997]). En effet, un mauvais démarrage, c'est-à-dire avec des phases de sécheresse, pendant la phase reproductive peut avoir un impact négatif sur les rendements finaux. Certaines années, par exemple 1998, 1999, 2002 et 2006 ont un démarrage assez tardif. Au contraire, les années 2003, 2005, 2008, 2010 et 2012 ont un démarrage précoce. On peut aussi identifier certaines années avec globalement des déficits d'eau, comme 2000, 2004, 2009, ou d'autres étant anormalement humides, comme 2003, 2010 ou encore 2012.

Sur la Figure 4.15 sont représentées, en pointillés, les 2 périodes, P1 et P2, identifiées à l'échelle locale. Ainsi, en analysant la relation uniquement pendant P2, la période identifiée comme la plus sensible à l'échelle locale, on obtient la Figure 4.16 a), avec un  $R^2$  de 0.55 entre les anomalies d'humidité du sol à 30 cm et les anomalies FAO de rendement de mil. Quelques années semblent alors mal expliquées, par exemple les années 2006, 2007, 2013 ou encore 2014. Pour 2006, 2007 et 2013, l'anomalie d'humidité du sol semble trop haute. Or, en considérant aussi la première période P1, on remarque qu'elle est anormalement sèche. Pour 2014 c'est l'inverse, P2 est très sèche alors que P1 est humide.

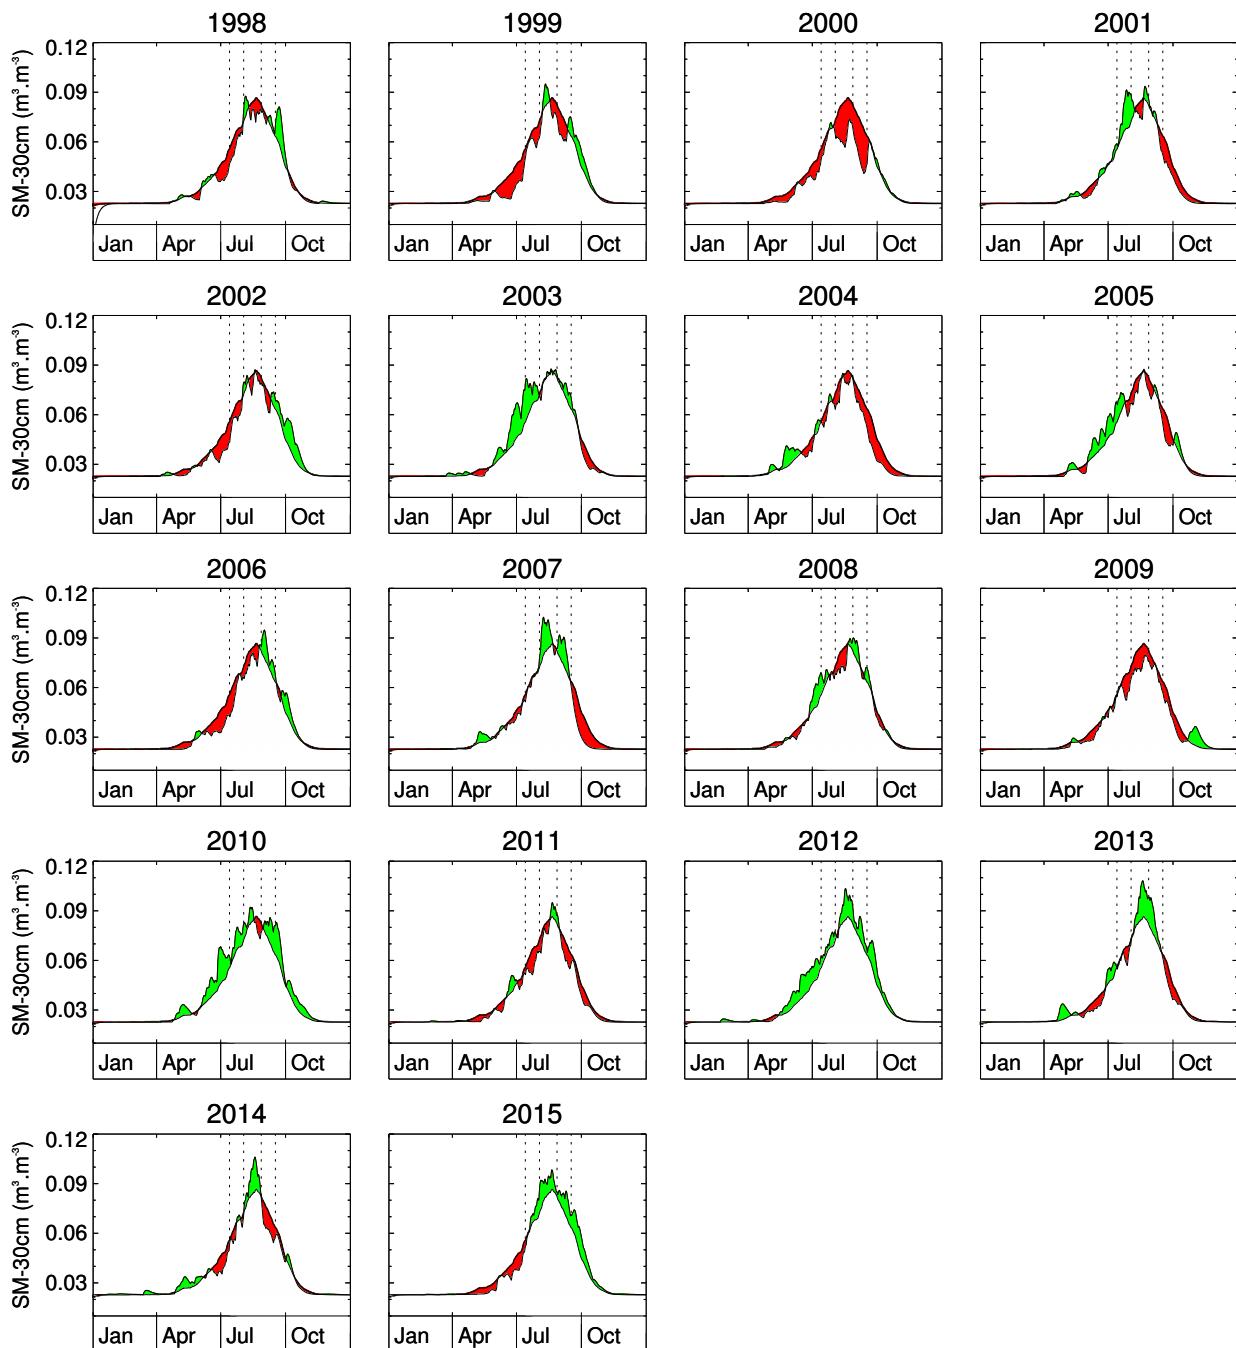


FIGURE 4.15 – Étude climatologique de l'humidité du sol simulée à 30 cm dans la zone de culture du mil au Niger pour les 18 années de 1998 à 2015. Respectivement, les périodes plus humides que la climatologie sont en vert et les plus sèches sont en rouge.

Ainsi, en combinant les périodes P1 et P2 (avec respectivement une pondération 0.4 et 0.6), la relation passe à  $R^2=0.62$ . La Figure 4.16 montre la différence entre l'utilisation d'une seule, partie a), ou des deux périodes, partie b). On remarque alors que les anomalies pour les années avec un démarrage tardif de la saison des pluies (1998, 1999, 2002 et 2006) montrent maintenant une meilleure proportion à estimer le rendement annuel de mil à Niger. Cette diminution a pour conséquence de se rapprocher des anomalies de rendements. Et de même pour les années avec un démarrage précoce de la saison des pluies (2003, 2005, 2008, 2010 et 2012), l'ajout de la première période tend à augmenter positivement les anomalies.

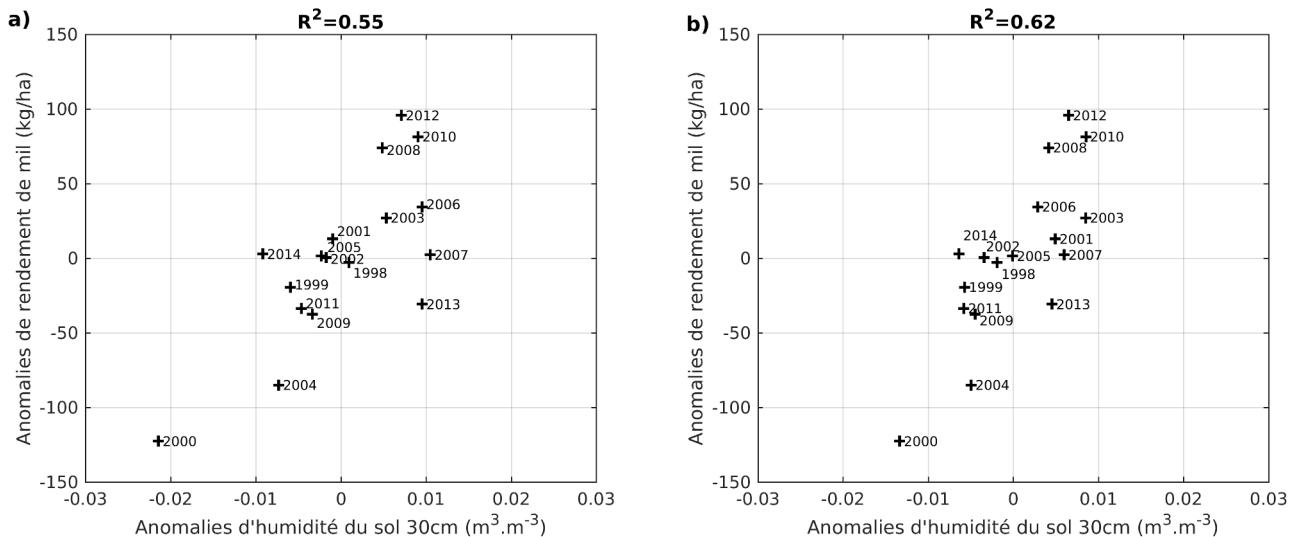


FIGURE 4.16 – Comparaison entre les anomalies d'humidité du sol calculées à partir d'une seul période (en a)) et des deux périodes (en b)). La prise en compte de la période reproductive en plus de la période de remplissage de grain permet l'explication de 62% de la variance annuelle des rendements de mil au Niger (données FAO).

#### 4.5.4 Analyse de la variabilité spatiale

Les cartes d'humidité du sol à 30 cm,  $\theta_{(t)}^{30cm}$ , développées dans les parties précédentes, à une résolution de  $0.25^\circ/3h$ , permettent une analyse de la distribution spatiale des anomalies d'humidité. Sur la Figure 4.17 sont représentées les distributions spatiales des anomalies d'humidité du sol pour les 17 années à partir des 2 périodes (40% de période reproductive et 60% de la période de remplissage). Le rectangle noir représente la zone où l'étude *in-situ* a été réalisée.

A partir de l'analyse de ces cartes, on peut expliquer certaines différences entre les variations de rendement mesurées localement et celle données par la FAO. En effet, pour l'année 2004, le rendement mesuré localement est le meilleur des 9 années (voir Figure 4.6) avec 881 kg/ha pour une moyenne de 665 kg/ha, soit 216 kg/ha de plus que la moyenne, alors que la FAO rapporte un rendement inférieur, à savoir 364 kg/ha pour une moyenne de 448 kg/ha, soit -84 kg/ha). Cela peut être expliqué par l'anomalie positive d'humidité au niveau de la région de Niamey (rectangle noir) alors que le reste de la carte est en anomalie négative. La situation inverse est identifiable pour l'année 2012. En effet, les mesures *in-situ* donnent un rendement inférieur (de 188 kg/ha) à la moyenne alors que la FAO donne un rendement supérieur (de 56 kg/ha) à la moyenne. Cela peut être expliqué par la zone sèche autour de Niamey alors que le reste de la carte est exceptionnellement humide.

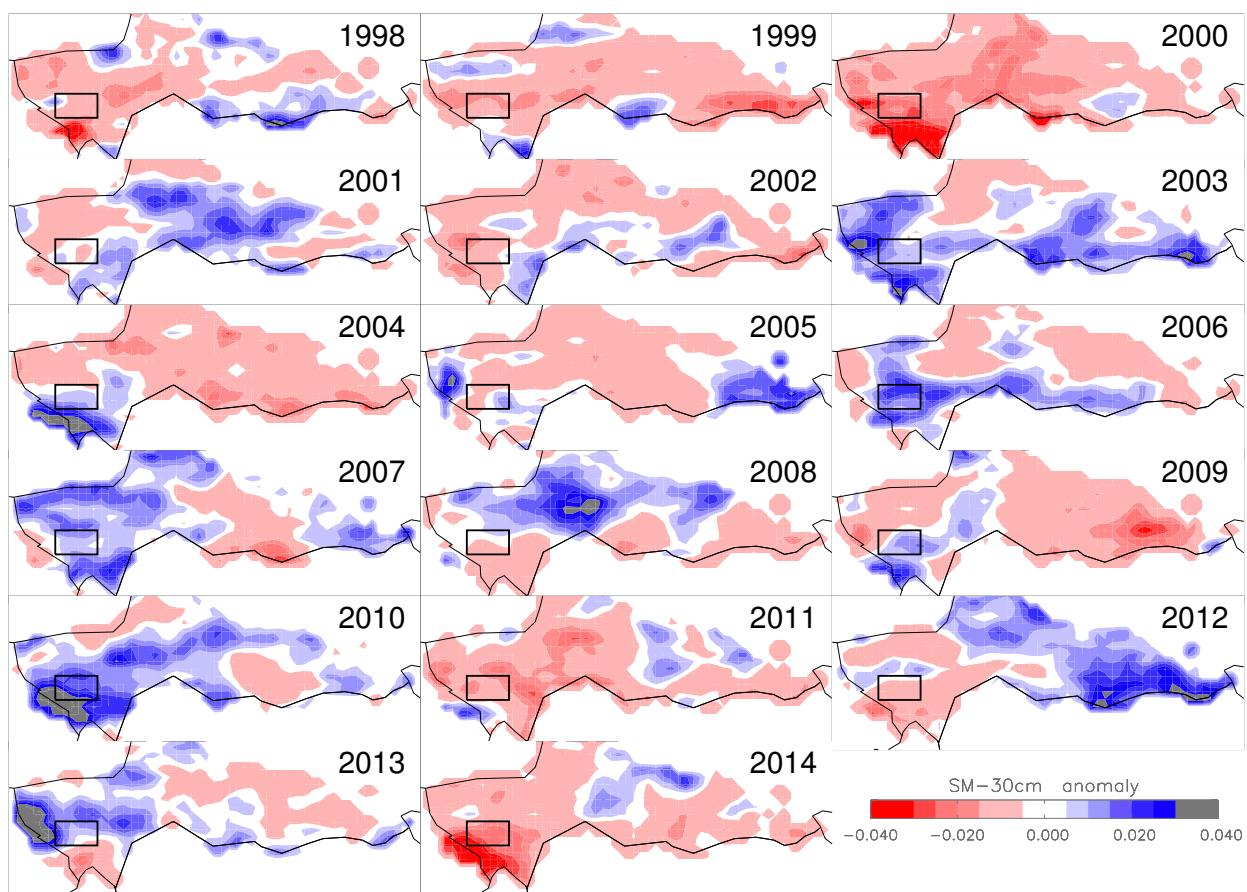


FIGURE 4.17 – Cartes d'anomalies d'humidité à 30 cm,  $\theta_{(t)}^{30cm}$ , sur les périodes 0.4\*P1+0.6\*P2, pendant les années 1998–2014. Le carré noir est la zone autour de Niamey analysée dans l'étude locale.

Ces cartes permettent aussi d'analyser les discordances entre anomalies d'humidité et anomalies de rendement observé par exemple pour les années 2003 et 2008. En effet, l'année 2003 est plus humide que 2008, alors que la FAO indique un rendement meilleur en 2008 qu'en 2003. Or, après analyse de la carte de 2003, on observe qu'elle est anormalement humide dans la partie sud alors qu'en 2008 elle l'est dans la partie nord. Le gradient pluviométrique latitudinal rend la zone sud moins sensible aux anomalies négatives que la zone nord. Une anomalie négative d'humidité dans la zone sud n'est pas forcément synonyme de stress hydrique pour les cultures, alors qu'au contraire, la zone nord est globalement plus sèche, donc une anomalie négative tend logiquement plus facilement vers du stress hydrique. Cela est aussi vrai pour les anomalies positives. Dans le nord, une anomalie positive a sûrement plus d'impact (positif) que dans le sud. Le gradient tend donc vers une plus grande sensibilité du nord de la région aux anomalies d'humidité.

Une étude à l'échelle des districts administratifs a été effectuée : voir [Annexe E : Analyse à l'échelle des districts administratifs](#).

## 4.6 Étude à l'échelle régionale

### 4.6.1 Relation à l'échelle de la bande sahélienne

Maintenant que nous avons étudié la relation entre humidité du sol et rendement de mil au Niger, essayons d'appliquer cette relation à d'autres pays du Sahel. La carte de la Figure 4.18 montre les surfaces cultivées de mil pour la bande sahélienne.

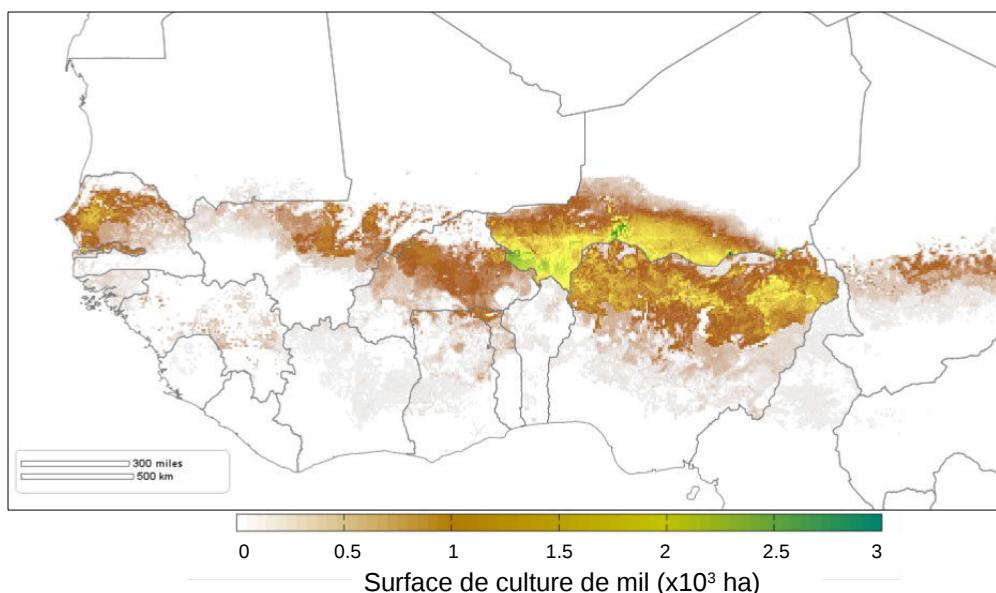


FIGURE 4.18 – Carte des surfaces cultivées de mil pour l'année 2000 (données Global Agro-Ecological Zones, GAEZ).

La base de données de la FAO nous fournit des données de rendement pour d'autres pays que le Niger, à savoir pour cette étude : le Sénégal, le Burkina Faso et le Mali. Les données de rendements sont représentées Figure 4.19. On observe alors une différence dans les rendements moyens de chacun des pays, avec dans l'ordre croissant : le Niger, le Sénégal, le Mali et le Burkina Faso.

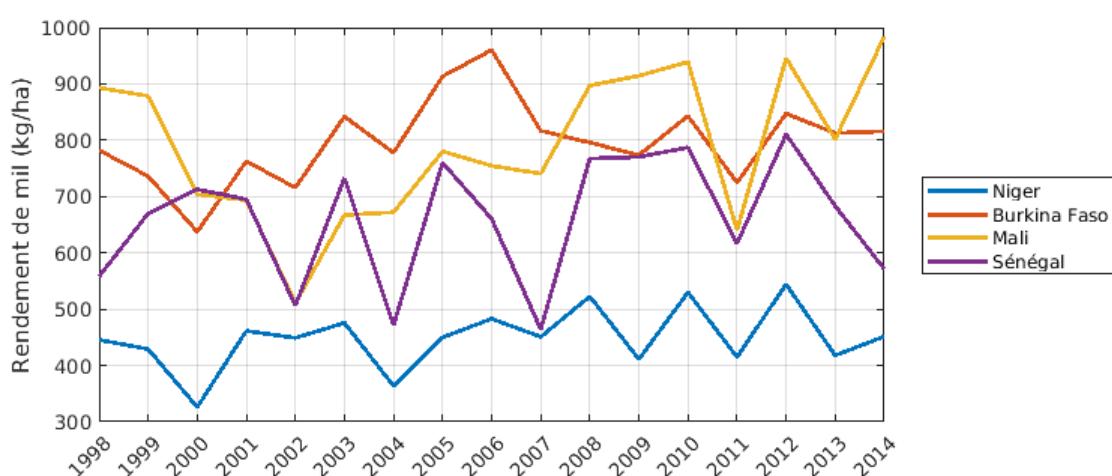


FIGURE 4.19 – Évolution des rendements de mil selon la base de données FAOSTAT pour les pays du Niger (en bleu), du Burkina Faso (en rouge), du Mali (en jaune) et du Sénégal (en violet).

La Figure 4.19 montre des valeurs de rendement moyen très variables d'un pays à l'autre ; dans l'ordre croissant : le Niger avec 449 kg/ha, le Sénégal avec 661 kg/ha, le Mali avec 789 kg/ha et le Burkina Faso avec 797 kg/ha. On observe aussi que les variabilités annuelles sont assez élevées entre les pays, avec une amplitude de  $\pm 300$  kg/ha pour le Burkina Faso, le Mali, le Sénégal et  $\pm 200$  kg/ha pour le Niger.

Afin d'étudier la relation à cette échelle, il est nécessaire de modéliser l'humidité à 30 cm sur toute les zones cultivées. Pour cela, toutes la zone représentée Figure 4.18 a été modélisée avec l'API, puis les humidités moyennes calculées sur les périodes P1 et P2 sont représentées Figure 4.20.

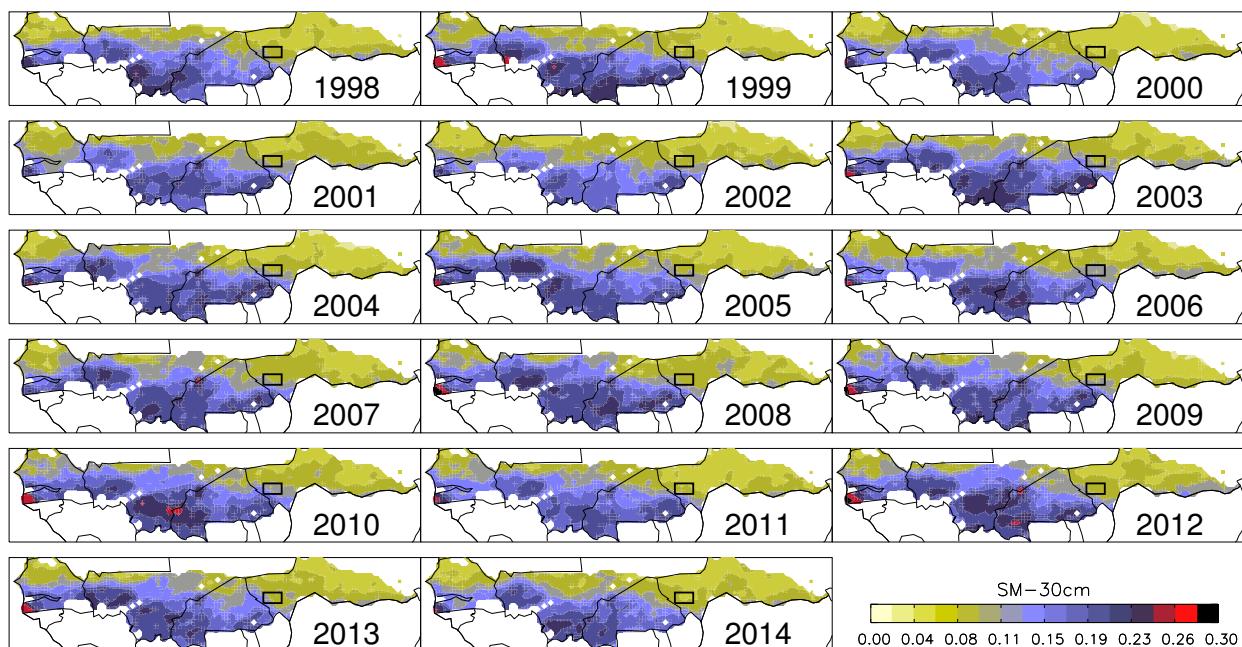


FIGURE 4.20 – Moyenne des humidités du sol à 30 cm (en  $\text{m}^3 \cdot \text{m}^{-3}$ ) sur les périodes P1 (13/07–2/08) et P2 (27/08–16/09), avec une pondération de 40 et 60% respectivement.

Sur la Figure 4.20, on remarque que l'humidité du sol pendant ces périodes est très marquée par le gradient latitudinal. En effet, sur les 17 années, l'humidité du sol est autour de  $0.2 \text{ m}^3 \cdot \text{m}^{-3}$  pour le sud du Burkina Faso et le sud du Mali alors qu'elle oscille autour de  $0.08 \text{ m}^3 \cdot \text{m}^{-3}$  dans la partie nord de la zone de culture. Cependant, il est difficile d'interpréter la variabilité de ces cartes sous ce format. Les anomalies d'humidité ont donc été calculées Figure 4.21.

Sur la Figure 4.21, les anomalies d'humidité dérivées sur les 4 pays nous permettent d'analyser spatialement les déficits hydriques pendant les 17 années sur les 2 périodes les plus sensibles. On retrouve ainsi les années globalement sèches (2000, 2002), et humides (2008, 2010 et 2012). D'un point de vue des rendements, analysons chacun des pays. Pour le Sénégal, la répartition des cultures est plutôt concentrée dans la partie ouest du pays (voir carte Figure 4.18). Ainsi, en analysant les cartes d'anomalies d'humidité Figure 4.21, on s'aperçoit que les années où les rendements sont les plus faibles (1998, 2002, 2004, 2007 et 2014) correspondent aux années où les anomalies négatives d'humidité dépassent les  $-0.03 \text{ m}^3 \cdot \text{m}^{-3}$  dans l'ouest du pays. Pour le Mali, les rendements sont relativement bas pour la période 2000–2007 puis sont plus haut sur la période 2008–2014, on peut alors retrouver une tendance (relativement faible) sur les cartes d'anomalies d'humidité correspondantes. Pour le Burkina Faso, la zone cultivée se situe au centre du pays. On peut alors identifier les mauvaises années de rendement à partir des

## 4.6. ÉTUDE À L'ÉCHELLE RÉGIONALE

cartes d'anomalies d'humidité en 2000, 2002 et 2011. Pour le Niger, les détails ont été présentés dans les parties précédentes.

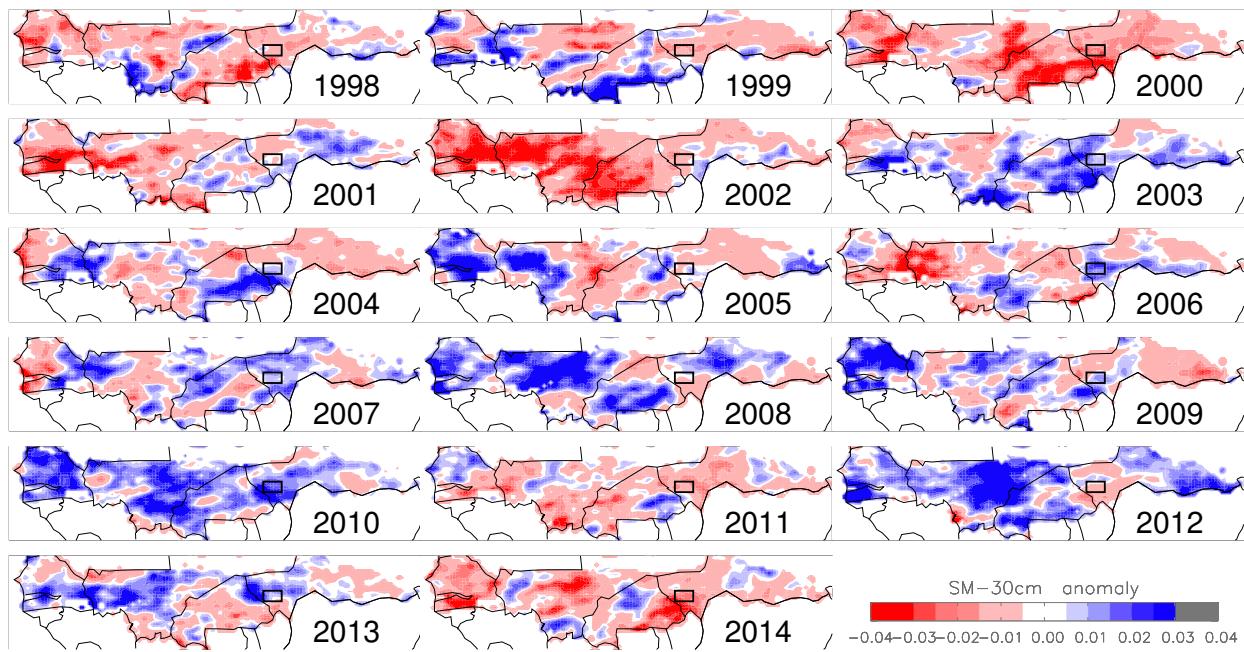


FIGURE 4.21 – Anomalies d'humidité du sol sur les périodes P1 et P2 sur la bande Sahélienne (Burkina Faso, Mali, Niger et Sénégal).

Afin d'aller plus loin dans l'analyse, une régression entre les humidités sur les zones de culture (carte 4.18) pendant les périodes, P1 et P2, et les valeurs de rendement de la FAO pour chacun des pays a été réalisée. Le résultat, Figure 4.22 montre un score  $R^2=0.75$  pour l'ensemble des pays.

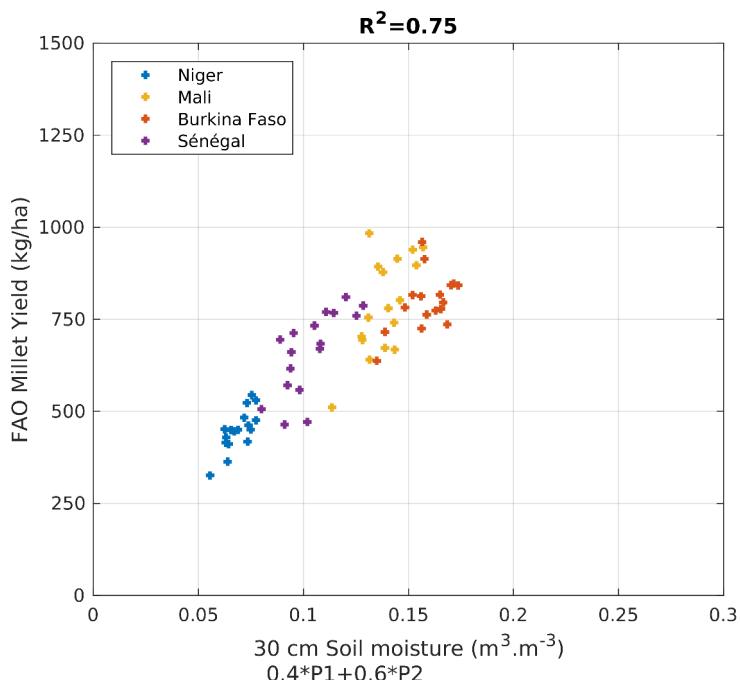


FIGURE 4.22 – Évolution des rendements en fonction des humidités moyennes sur les périodes  $0.4*P1+0.6*P2$ , pour le Niger, le Mali, le Burkina Faso et le Sénégal.

### 4.6.2 Vers des cartes de rendement ?

Nous avons vu précédemment le potentiel explicatif des anomalies de rendement par les anomalies d'humidité du sol. L'idée qui découle de ces observations est celle de développer un modèle entre la valeur absolue de l'humidité du sol et les valeurs absolues de rendement. Pour cela, un modèle de régression est défini à partir de la courbe en pointillés noirs de la Figure 4.25.

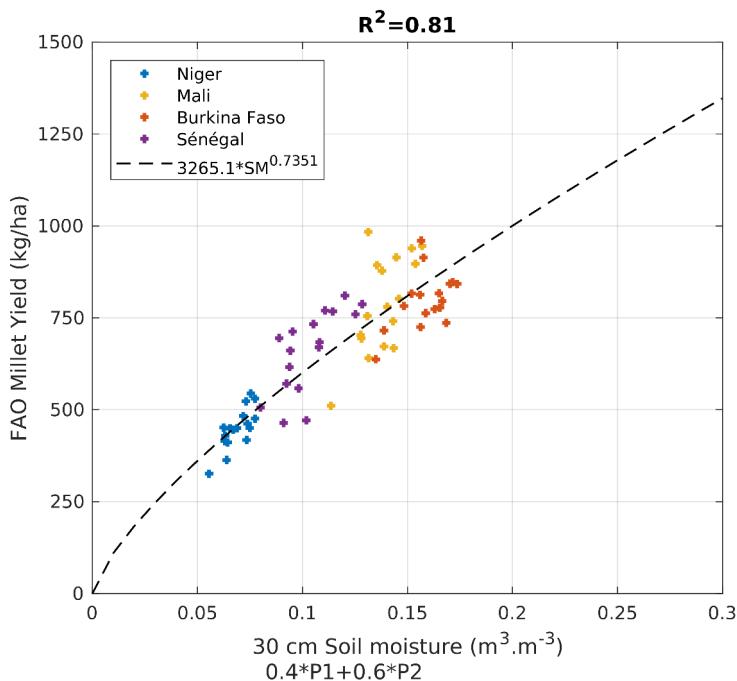


FIGURE 4.23 – Modèle en puissance Rendement=f(humidité).

Cette courbe de régression ( $R^2=0.81$ ), en fonction de puissance, est définie par :

$$Yield = 3265.1 \times \theta_{30cm}^{0.7351} \quad (4.3)$$

avec  $Yield$  le rendement estimé et  $\theta_{30cm}$  l'humidité du sol simulée à 30 cm (et moyennée sur les périodes P1 et P2 avec une pondération de 40 et 60% respectivement).

Des cartes de rendement à l'échelle du Sahel ont ensuite été calculées à partir des cartes d'humidité Figure 4.20 et de l'équation (4.3). Ces cartes, Figure 4.24, représentent la distribution spatiale du rendement estimé à partir de l'humidité du sol pour les années 1998 à 2014. On y observe des rendements autour de 1000 kg/ha dans le sud du Burkina Faso et autour de 400 kg/ha au Niger. Sur ces cartes, on peut également distinguer les années pour lesquelles les rendements estimés sont assez bas : 2000, 2004 et 2009 pour le Niger. Ces années correspondent bien aux plus basses valeurs de rendements selon la FAO. Cependant, il est difficile d'apprécier en détail les rendements sur ces cartes.

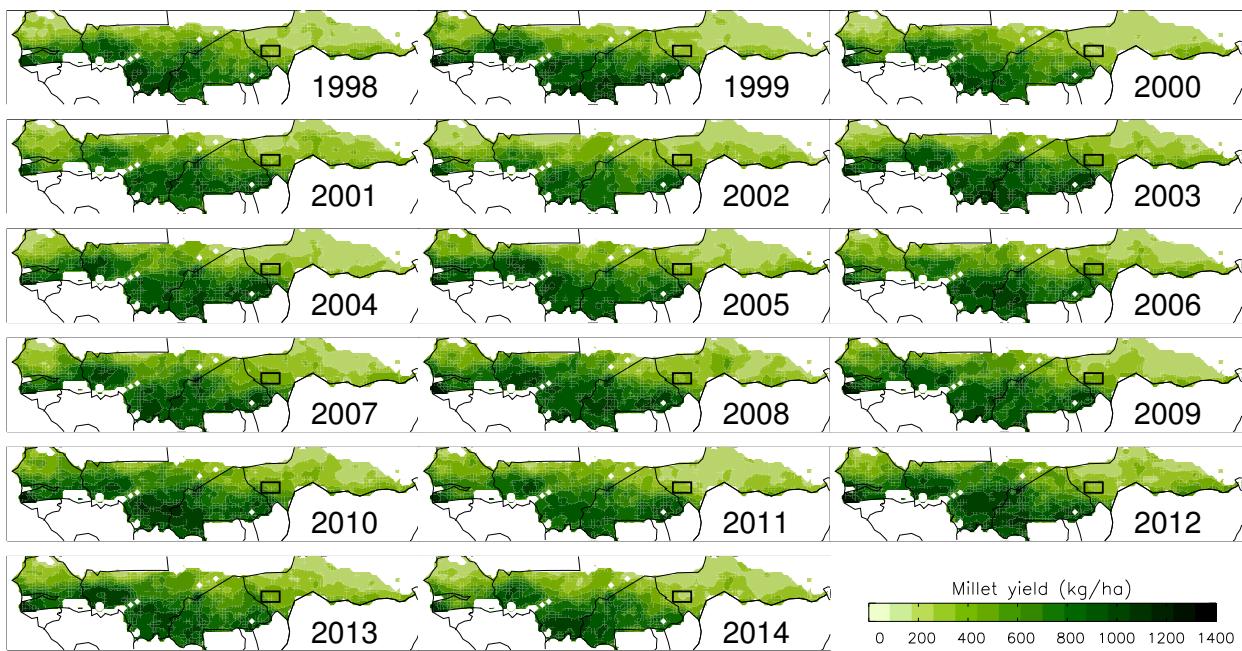


FIGURE 4.24 – À partir du modèle décrit dans l'équation (4.3) défini entre humidité du sol et rendement, des cartes de rendements ont été calculées pour les 17 années. Le carré noir correspond à la zone de Niamey.

Afin d'évaluer la précision de ces estimations de rendement, la moyenne spatiale a été réalisée sur l'ensemble de la zone cultivée pour chaque pays et pour les 17 années. La Figure 4.25 compare ainsi les rendements estimés et les rendements FAO. On remarque que les rendements sont assez bien estimés avec un  $R^2=0.77$  et un RMSE de 82.1 kg/ha pour les 4 pays. Cependant, certaines années semblent assez mal expliquées par la méthode, avec des erreurs d'estimations pouvant atteindre  $\pm 200$  kg/ha pour le Sénégal et le Mali par exemple.

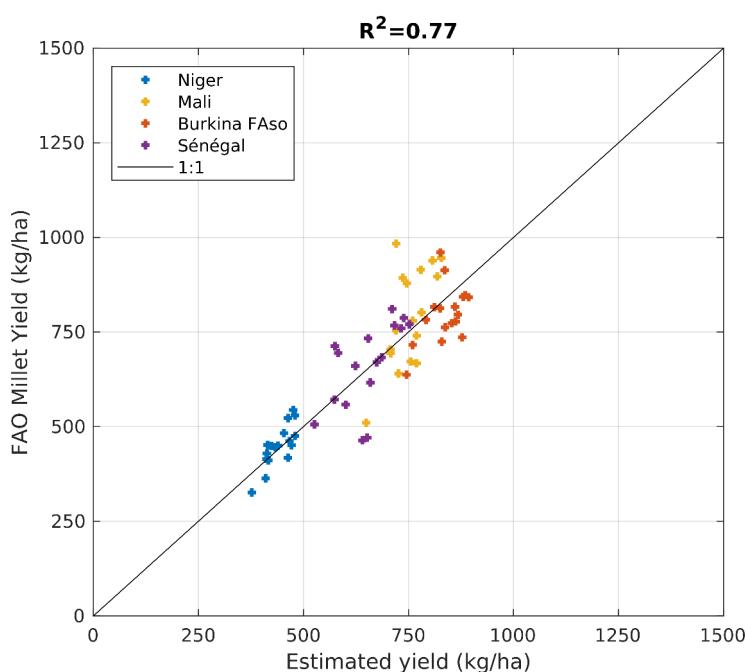


FIGURE 4.25 – Comparaison entre rendement fourni par la FAO pour les 4 pays et les rendements estimés par l'humidité du sol.

## 4.7 Résumé et conclusion

Les impacts des changements climatiques sur l'agriculture sont encore difficiles à évaluer. Cependant, certaines régions, comme l'Afrique de l'Ouest, connaissent déjà des contraintes multifactorielles très fortes (climat, démographie, agriculture pluviale et de subsistance, ...). Observer les variations de rendement à l'échelle régionale permet d'alimenter les données disponibles pour les décisionnaires. L'objectif de ce chapitre était d'étudier le potentiel de l'humidité du sol à expliquer les variations de rendement de mil en Afrique de l'Ouest.

Dans un premier temps, une évaluation de la relation entre humidité du sol et rendements agricoles a été effectuée à partir de données *in-situ* autour de Niamey, au Niger. Pour cela les données in-situ d'humidité du sol ont été comparées en termes d'anomalies, aux anomalies de rendements agricoles du village le plus proche. Il en a résulté l'identification de 2 périodes de 20 jours où les anomalies d'humidité du sol à 30 cm expliquaient les anomalies de rendements, courant juillet et fin-août/mi-septembre, avec un  $R^2$  de 0.6. Ces 2 périodes correspondent, pour les plantes, aux périodes phénologiques de reproduction et de remplissage de grains.

Dans un second temps, 9 villages au Niger ont été étudiés. Pour cela les humidités du sol à 30 cm ont été simulées à partir de modélisations forcées par des pluies issues de pluviomètres. Les résultats montrent une certaine variabilité des périodes, village par village, mais en considérant l'ensemble des villages, le signal est relativement fort ( $R^2=0.77$ ) sur les périodes 13/07–2/08 et 27/08–16/09.

Une étude à l'échelle du Niger a ensuite été effectuée. Pour cela, les cartes d'humidité du sol ont été simulées à partir de l'API forcé par le produit de précipitation CMORPH-ADJ. Sur ces cartes, les humidités pendant les 2 périodes identifiées précédemment ont été analysées et comparées au rendement fourni par la FAO. Les scores montrent une bonne représentation des variations à l'échelle nationale sur 17 ans ( $R^2=0.62$ ). A l'échelle des districts administratifs, les résultats montrent une dépendance à la production, avec une relation de meilleure qualité dans les zones produisant le plus.

Cette méthode a ensuite été appliquée à d'autres pays du Sahel. Les résultats montrent une bonne cohérence entre les variations d'humidité du sol au Niger, au Mali, au Burkina Faso et au Sénégal ( $R^2=0.75$ ). De cette étude, un modèle statistique Rendement=f(humidité) a été proposé afin de générer des cartes de rendements sur toute la zone du Sahel. La régression entre les moyennes des rendements estimées par pays et les données de la FAO pour les 17 années, donnent une corrélation de  $R^2=0.77$  avec une erreur de RMSE=82.1 kg/ha.

### Prochain chapitre

Dans ce chapitre nous avons vu que les estimations d'humidité du sol permettaient d'expliquer une certaine variabilité des rendements agricoles de mil en Afrique de l'Ouest. Cependant la question de la qualité des forçages de précipitations, et de leurs délais de distribution restent un verrou pour ce type d'étude. Dans le prochain chapitre nous verrons donc comment utiliser la méthode d'assimilation pour corriger les produits de précipitation en quasi temps-réel.



# Chapitre 5

## Correction des produits de pluies satellite par assimilation de SMOS dans un modèle de surface

---

<b>5.1</b>	<b>Introduction</b>	118
<b>5.2</b>	<b>Correction des précipitations via l'assimilation de SMOS</b>	120
5.2.1	Description de la méthode	120
5.2.2	Évaluation sur les sites du Niger et du Bénin	122
5.2.3	Quel est le potentiel de correction maximal de la méthode ?	125
5.2.3.1	Expérience 1 : Impact de l'assimilation sur les pluies <i>in-situ</i>	125
5.2.3.2	Expérience 2 : Observations "parfaites" et forçages incertains	125
5.2.3.3	Limitations	126
<b>5.3</b>	<b>Vers un produit haute résolution spatiale avec le produit TAMSAT</b>	127
5.3.1	Le produit de précipitation TAMSAT	127
5.3.2	Détail de la chaîne de traitement	128
5.3.3	Résultats et discussion	131
5.3.3.1	Évaluation locale	131
5.3.3.2	Évaluation à l'échelle du continent africain	135
<b>5.4</b>	<b>Résumé et conclusion</b>	137

---

## 5.1 Introduction

L'estimation des précipitations à l'échelle globale à haute résolution spatiale et temporelle est un véritable challenge, particulièrement en Afrique de l'Ouest. La forte variabilité des précipitations due à la mousson ainsi que leur fort impact sur les populations rend leur suivi particulièrement important ([Lesk et al., 2016]). Estimer le régime des précipitations passées, présentes et futures permettra donc de mieux comprendre les interactions avec la biosphère et ainsi mieux diriger les actions garantissant une meilleure adaptabilité aux changements climatiques. Cependant, la densité du réseau de pluviomètres est assez faible dans cette région ( $1/1000 \text{ km}^2$ ) et ne permet qu'une description très incertaine de la structure spatiale et temporelle des précipitations. Les radars météo, dont l'emploi est une autre solution un peu plus intégratrice en termes de représentativité spatiale, sont encore moins nombreux dans cette région. Restent donc les produits de précipitations issus d'information satellitaire. Ces produits sont basés sur différentes informations concernant la température du sommet du nuage (infrarouge) et le contenu en eau dans la colonne atmosphérique (micro-onde). Représentant les précipitations à l'échelle globale, ces derniers ont cependant de fortes incertitudes sur les intensités de pluies estimées. En d'autres termes, les événements de pluie (occurrences) sont vus mais les intensités mal estimées [Maidment et al., 2017]. De mauvaises estimations sur la quantité de précipitations peuvent avoir des incidences sur les modèles agronomiques, voir Figure 5.1 tirée de [Ramarohetra et al., 2013].

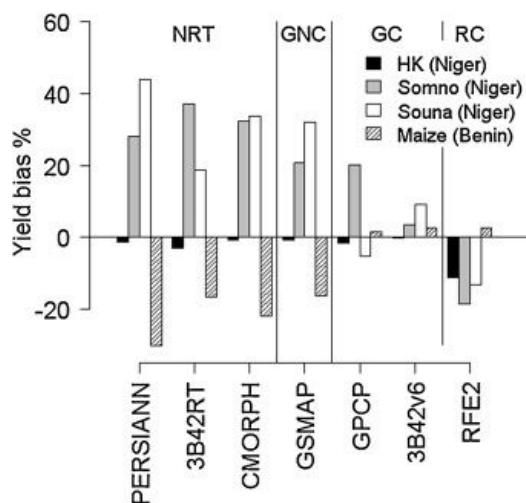


FIGURE 5.1 – Sensibilité du modèle SARRAH aux erreurs de différents produits de pluies satellites (figure de [Ramarohetra et al., 2013]).

Sur cette figure, est représenté le biais de rendements de différentes cultures, simulés par le modèle SARRA-H pour différents forçages pluviométriques. On observe que la sensibilité des rendements simulés est assez forte au choix du produit de précipitation utilisé, générant des biais importants dans les estimations des rendements finaux.

Une autre problématique réside aussi dans la résolution spatiale des produits de précipitation. En effet, la plupart des produits cités ont des résolutions spatiales très larges ( $0.25^\circ$ ). Or, cette large échelle, que ce soit au niveau des précipitations que des estimations d'humidité du sol à l'échelle globale, est souvent un frein à leur utilisation. La question de la désagrégation spatiale est une question critique pour les problématiques agricoles. Dans la review [Peng et al., 2017], les auteurs font un état de l'art des différentes méthodes d'estimation d'humidité du sol haute résolution, c'est-à-dire : la télédétection radar, l'utilisation de proxies physiques (température de surface (LST), végétation (NDVI), évapotranspiration (ET),...), méthodes mathématiques

(transformation ondelette, fractales), utilisation modèles de surface ainsi qu'assimilation de données. C'est ce dernier point que nous allons aborder ici.

La proportion des précipitations qui s'infiltrent dans le sol contribue aux variations de son humidité, qui garde ainsi une "mémoire" de la quantité de précipitation tombée, et ce, même après plusieurs jours ([[Seneviratne et al., 2006](#)], [[McColl et al., 2017](#)] ). Certaines études montrent qu'il est possible de se baser sur les données d'humidité du sol à partir de télédétection pour estimer les précipitations ([[Crow et al., 2011](#)], [[Pellarin et al., 2013](#)], [[Brocca et al., 2014](#)], [[Román-Cascón et al., 2017](#)]). Le [Chapitre 3](#) présente une méthode d'assimilation permettant d'améliorer les humidités du sol simulées à partir de précipitations. Or cette méthode agissant directement sur le taux de précipitations, modifie l'intensité des événements.

Dans [[Román-Cascón et al., 2017](#)] nous avons évalué les qualités de corrections des précipitations de la méthode sur 10 sites à travers le monde (dans le cadre du projet ESA SMOS RAINFALL).

Dans la seconde partie de ce chapitre nous allons voir comment appliquer la méthode de correction des pluies à un produit de précipitation spécifique au continent Africain : Tropical Application of Meteorology using SATellite and ground based observation (TAMSAT). Dans le chapitre sur l'assimilation nous avons vu une méthode ensembliste visant à obtenir une meilleure humidité du sol à partir d'une information de pluie perturbée. L'idée de ce chapitre est donc de créer un produit composite TAMSAT en intégrant SMOS. Pour cela nous aborderons tout d'abord les grandes lignes de la méthode. Puis dans un second temps plus spécifique au produit TAMSAT, nous aborderons la description de la chaîne de traitement avec le détail de chacune des étapes. Enfin, nous évaluerons le produit obtenu à l'échelle locale et régionale.

## 5.2 Correction des précipitations via l'assimilation de SMOS

### 5.2.1 Description de la méthode

Dans cette partie nous allons voir comment, en modifiant les précipitations, le filtre particulier mis en place ici permet de réduire les incertitudes sur les précipitations. Reprenons la Figure de l'article [Román-Cascón et al., 2017], Figure 5.2.

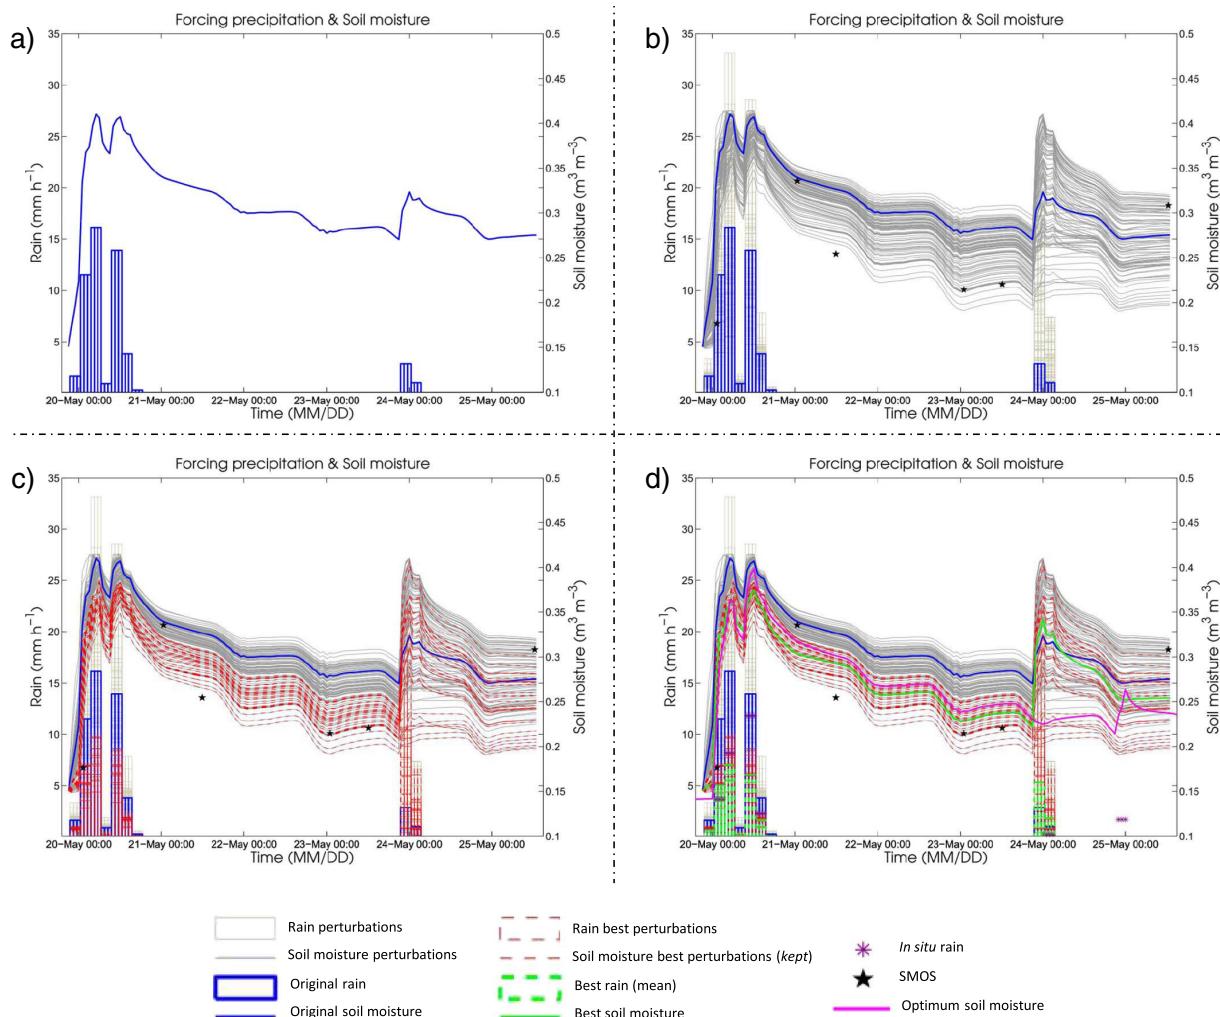


FIGURE 5.2 – La méthode se divise en 4 étapes principales. La première, a), est la simulation de l'humidité du sol (trait plein bleu) à partir du produit de pluie (barres bleues) à corriger dans le modèle de surface. Ce produit de pluie est ensuite perturbé afin de créer un ensemble de trajectoire (traits gris) en b), puis échantillonné (traits rouges) en c) et corrigé (traits vert) en d).

La description de la séquence est effectuée au Chapitre 3 [Filtre particulier](#). Cependant, le caractère non-linéaire de la relation précipitation-humidité est à prendre en compte ici. En effet, sur la Figure 5.3, on peut observer la réponse de l'API à différentes valeurs de précipitations. On remarque alors que lorsque les précipitations excèdent 30-40 mm (au delà du rouge/orange), la sensibilité de l'humidité est assez faible. Cela pose la question de l'amplitude des perturbations. En effet, lors de la création de l'ensemble de trajectoire d'humidité, que les précipitations soient de 40 ou 200 mm/h, les différences sur les humidités sont relativement faible. Or, si l'amplitude de l'ensemble est faible, la discréétisation par les observations SMOS devient très sensible et les pluies sélectionnées peuvent être très intenses.

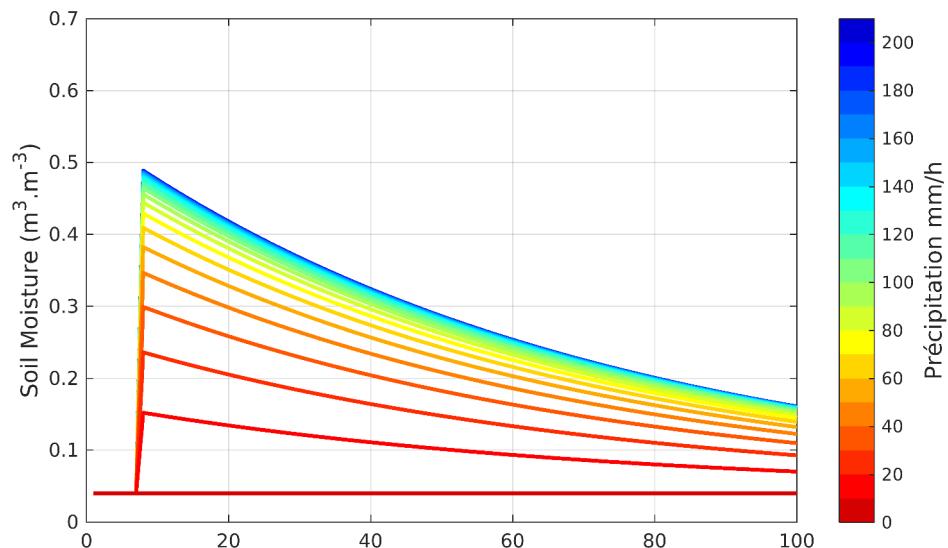


FIGURE 5.3 – Réponse non-linéaire de l'humidité du sol à un événement pluvieux (de 0 à 200 mm/h) à  $t = 10$  h.

Pour pallier ce problème, deux modes de perturbations ont été développés pour différentes gammes de pluies. Les perturbations ont été ici déterminées en analysant la distribution des rapports entre les événements de pluies *in-situ* et de pluies satellites. Deux "événements" de pluie sont définis comme indépendant lorsqu'ils sont séparés par 12 h sans pluie (on a donc deux événements sur la Figure 3.13). Ces événements ont été classés en deux différentes gammes, inférieure et supérieure à 30 mm. Ce seuil de 30 mm a été défini comme étant 70% de la cdf des pluies, voir a) de la Figure 5.4.

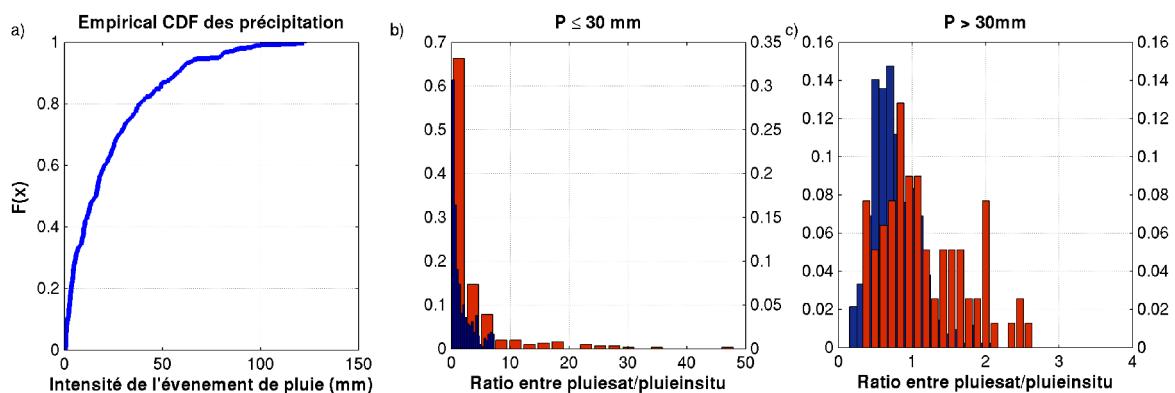


FIGURE 5.4 – En a) Distribution des pluies CMORPH RAW. En b) et en c) est représenté en rouge le ratio entre les événements de pluie satellite et *in-situ* et en bleu la fonction utilisée pour le coefficient multiplicateur  $k$ .

Ne pas appliquer la même perturbation sur toute la gamme de pluie évite de multiplier les événements de pluies forts par un fort coefficient et venir saturer le modèle. Pour les pluies inférieures et supérieures à 30 mm la distribution du ratio entre les pluies *in-situ* et satellite a été analysée, barres rouges sur b) et c) de la Figure 5.4. Ce ratio, sur l'axe des x, permet de connaître la distribution du coefficient multiplicateur à appliquer à la pluie satellite pour obtenir la pluie *in situ*. Ainsi deux fonctions ont été établies, voir équation (5.1). Ces deux fonctions sont représentées par les barres bleues Figure 5.4. Elles décrivent le tirage aléatoire

d'un coefficient multiplicateur  $k$  qui suit la distribution des ratios.

$$k = \begin{cases} e^{(4rand)-2} & \text{si } P \leq 30\text{mm} \\ 0.145randg(5.43) & \text{si } P > 30\text{mm} \end{cases} \quad (5.1)$$

$k$  est le coefficient multiplicateur appliqué à chaque événement de pluie comme décrit ici :

$$P_i(t) = k_i \times P(t) \quad \text{avec } i = 1 : 100 \quad (5.2)$$

$P(t)$  est la chronique de précipitation sur la fenêtre d'assimilation et  $P_i(t)$  l'ensemble des 100 chronologies de précipitations aléatoirement perturbée.

Pour les pluies supérieures à 30mm on utilise une loi gamma avec les paramètres de forme  $\alpha = 0.145$  et  $\beta = 5.43$  [Marsaglia and Tsang, 2000]. On retrouve les 2 cas Figure 3.13, le premier événement (20 mai) est supérieur à 30mm et donc subit le second cas de l'équation (5.1) et le second événement (24 mai) est inférieur à 30mm, il subit donc la perturbation exponentielle.

### 5.2.2 Évaluation sur les sites du Niger et du Bénin

Les Figures 5.5 et 5.6 représentent les cumuls annuels des produits avant et après assimilation, pour les sites du Niger et du Bénin. Les cumuls en pointillés sont issus des produits bruts, sans assimilation, et en trait plein après assimilation. Les cumuls sont comparés aux références, les traits noirs, correspondant aux mesures des pluviomètres.

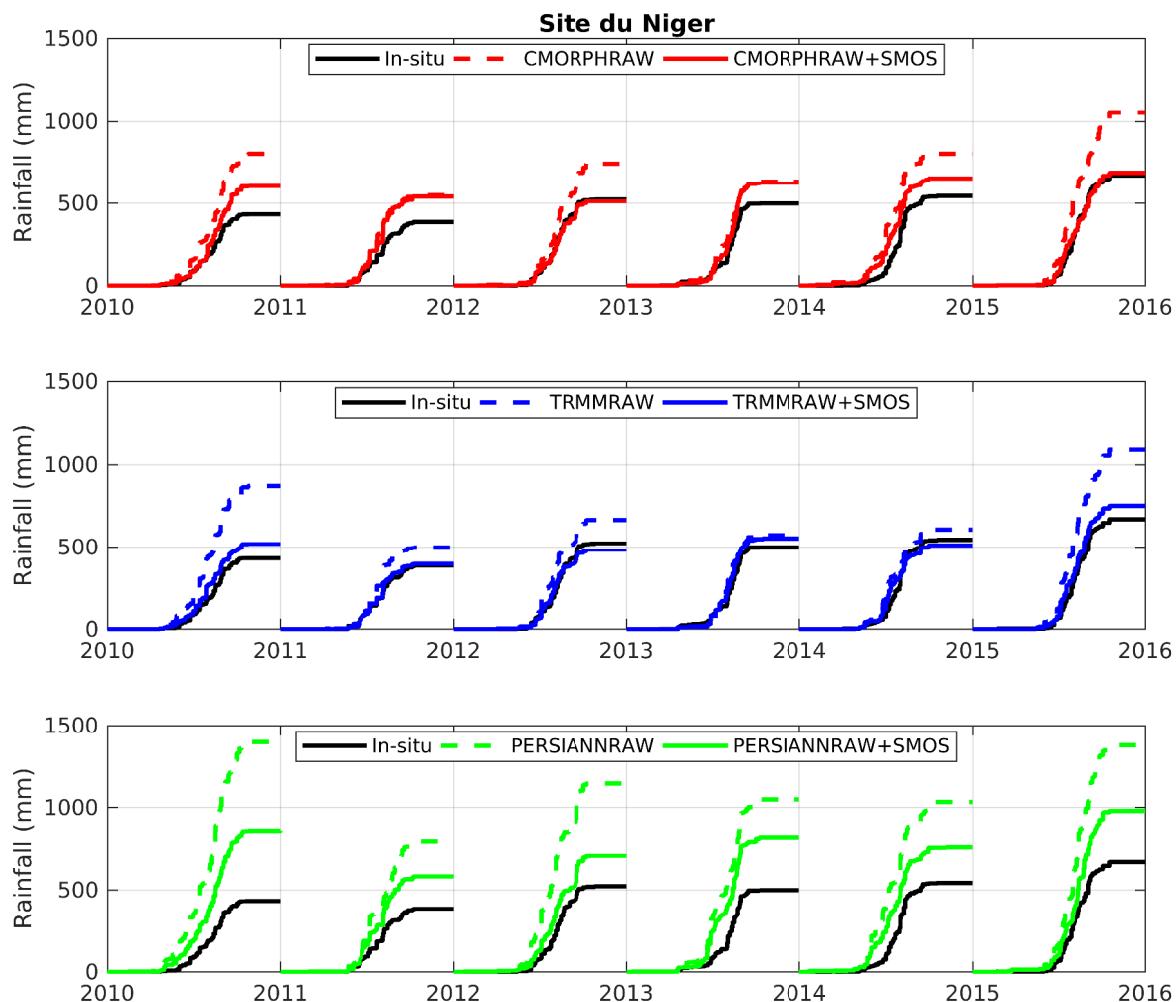


FIGURE 5.5 – Les produits de pluies satellite sont présentés ici sous la forme de cumuls annuels. Ils sont comparés aux mesures *in-situ* (en noir), pour le Niger. Les produits RAW (temps-réel) sont en pointillés et les produits intégrant SMOS en trait plein.

La Figure 5.5 montre l'impact de l'assimilation sur les différents produits temps-réel sous forme de cumuls annuels pour le site du Niger. L'objectif est de se rapprocher du cumul en noir, correspondant au cumul des produits *in-situ* issu des pluviomètres. On remarque alors que, quel que soit le produit, TRMM (en bleu), CMORPH (en rouge) ou PERSIANN (en vert), le produit après assimilation (en pointillé) est plus proche que le produit initial (en trait plein). Le constat est le même que pour le site du Bénin, à savoir une majorité de cumuls se rapprochant des cumuls *in-situ* avec quelques années semblant peu impactées (CMORPH 2011 et 2013 par exemple).

Cependant, représentées sous cette forme, certaines années semblent peu impactées par l'assimilation, comme l'année 2015 pour les produits CMORPHRAW et PERSIANN au Bénin ou encore CMORPH en 2011 au Niger. Or nous verrons par la suite que même si le cumul annuel n'a pas sensiblement changé, la dynamique inter-annuelle a bien été impactée, et améliorée.

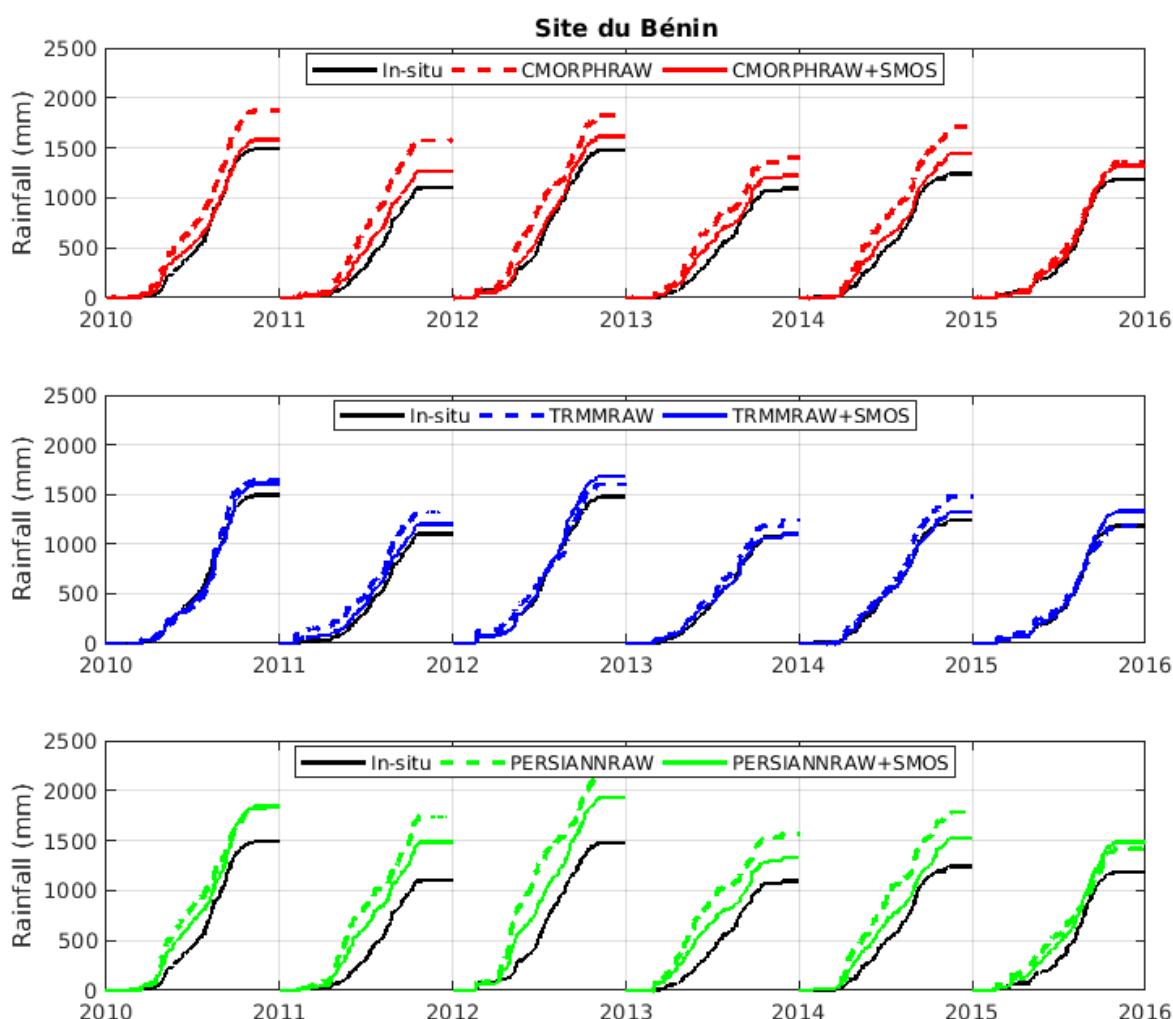


FIGURE 5.6 – Les produits de pluies satellite sont présentés ici sous la forme de cumul annuel. Ils sont comparés aux mesures *in-situ* (en noir), pour le Bénin. Les produits RAW (temps-réel) sont en pointillés et les produits intégrant SMOS en trait plein.

Afin d'évaluer l'apport de l'assimilation, le RMSE, le  $R^2$  et le biais sont calculés avant et après assimilation et représentés en valeurs relatives  $\Delta\text{RMSE}$ ,  $\Delta R^2$  et  $\Delta|bais|$  sur la Figure 5.7, tirée de [Román-Cascón et al., 2017]. Les barres correspondent à l'assimilation à travers l'API et les points à travers SURFEX. Ces différences correspondent à la soustraction des scores entre produit non assimilé vs. *in-situ* et produit assimilé vs. *in-situ*. Ainsi en vert sont représentées

les améliorations et en rouge les dégradations (résultats similaires pour les points).

Pour le RMSE journalier, Figure 5.7 a), l'apport de l'assimilation est très clair, avec une amélioration pour les deux sites, quelles que soient les années (une différence négative représente une amélioration du RMSE après assimilation). On remarque que les différences sont plus grandes pour PERSIANN, initialement plus mauvais que les autres produits, jusqu'à un RMSE de 4 mm/jour. Pour la corrélation, Figure 5.7 b), elles sont globalement meilleures. Cependant, quelques années comme 2010 au Niger ou 2011 au Bénin voient leurs corrélations détériorées après assimilation alors que les autres années sont considérablement améliorées (jusqu'à +0.18 de corrélation). Pour les cumuls annuels, Figure 5.7 c), les biais sont considérablement réduits, par exemple, d'environ 500 mm au Niger en 2010 avec PERSIANN. On retrouve ces améliorations sur les cumuls Figure 5.5.

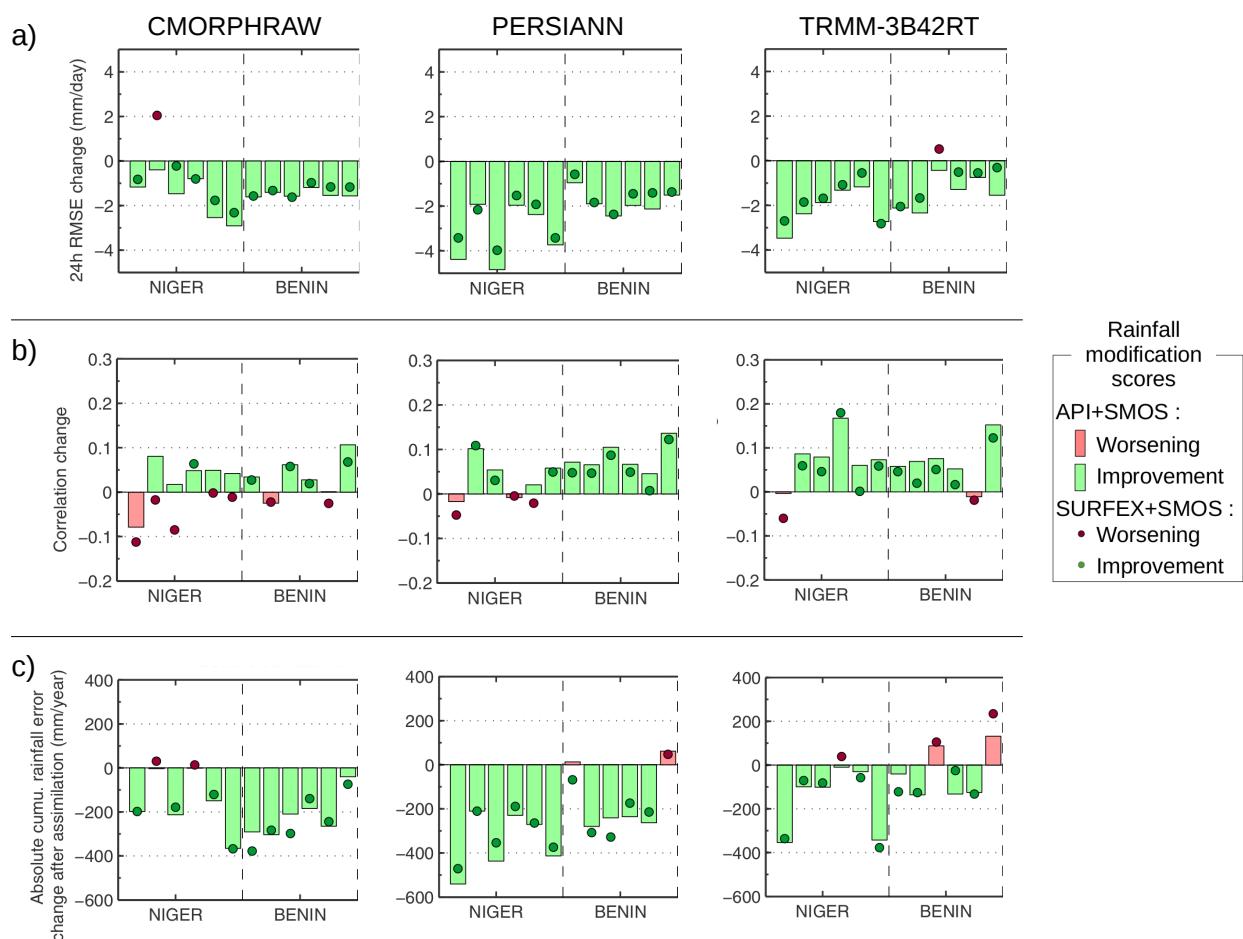


FIGURE 5.7 – Évaluation de l'apport de l'assimilation en terme de différences de scores entre le produit avant et après assimilation.

La Figure 5.7 présente aussi la comparaison entre les deux modèles API et SURFEX. Ces deux modèles ont été utilisés séparément dans le schéma d'assimilation. La première expérience, en assimilant au travers SURFEX donne les points de couleur et la seconde, en assimilant avec l'API, donne les barres. On remarque alors que les différences de scores semblent aller à l'avantage de l'API, qui montre majoritairement de meilleurs résultats.

### 5.2.3 Quel est le potentiel de correction maximal de la méthode ?

Les corrections effectuées par le filtre montrent un impact positif sur la réduction des erreurs de précipitations et sur les simulations d'humidité du sol associées. Cependant, le potentiel correctif du schéma doit être caractérisé afin d'analyser le potentiel maximal de correction et les limites du schéma. Pour cela nous présentons ici 2 expériences :

1. Étude de la dégradation des données des précipitations *in-situ* par assimilation d'observations SMOS.
2. Assimilation d'observations "parfaites" de SMOS afin d'évaluer le potentiel maximal de correction du filtre.

#### 5.2.3.1 Expérience 1 : Impact de l'assimilation sur les pluies *in-situ*

L'objectif de cette partie est de quantifier comment la méthode détériore les précipitations de référence. En effet, différents éléments, tel que le caractère ensembliste de la méthode, les non-linéarités ou encore les erreurs d'observations font que la méthode peut détériorer le produit de référence. Pour cela, il est proposé ici d'analyser les différences entre les produits de pluie *in-situ* avant et après assimilation de SMOS. Notons qu'il ne peut en résoudre qu'une dégradation du produit. Les résultats sont présentés Figure 5.8 pour les années 2010–2015 sur les sites du Niger et du Bénin.

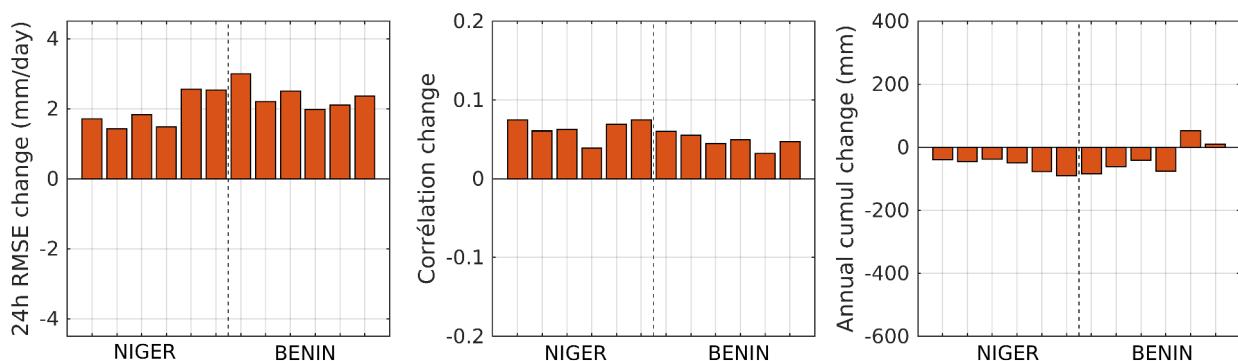


FIGURE 5.8 – Impact de l'assimilation de SMOS sur les précipitations *in-situ* en termes de RMSE journalier, de corrélation et de cumul annuel.

On observe sur la Figure 5.8 que la dégradation du produit de pluie en terme de RMSE est de 1.86 mm/jour en moyenne au Niger et de 1.98 mm/jour au Bénin. Pour les corrélations, ces dernières sont dégradées de -0.51 point au Niger et de -0.46 point au Bénin. Pour les cumuls annuels, ils ont tendance à être sous-estimés de -56.4 mm/an au Niger et de -56.4 mm/an au Bénin.

L'assimilation dégrade donc bien le produit de référence dans des ordres de grandeur qui sont raisonnable avec moins de 10% sur les cumuls annuels.

#### 5.2.3.2 Expérience 2 : Observations "parfaites" et forçages incertains

Cette seconde expérience a pour but d'étudier le potentiel de correction maximal du schéma d'assimilation. Pour cela, les données d'observations SMOS sont remplacées par des données synthétiques. C'est-à-dire de fausses observations SMOS générées à partir de l'humidité simulée par le modèle avec le produit de référence et échantillonées au passage de SMOS. Dans la théorie, ces nouvelles observations, appelées ici *observations "parfaites"*, simulent des observations SMOS sans erreurs. Afin de simuler le filtrage nous ne garderons que 300 de ces observations.

Ces observations "parfaites" sont utilisées ici pour assimiler les produits de pluie satellite incertains. L'objectif est double : (i) étudier le potentiel correctif maximal de la méthode et (ii) étudier l'impact de la réduction du nombre des observations SMOS utilisées à cause du filtrage. Pour ce second objectif, un jeu d'observations SMOS "parfaites" de 730 échantillons a été généré (730 correspond au nombre maximum des observations SMOS dans une année).

La Figure 5.9 représente l'impact de l'assimilation sur le produit CMORPHRAW assimilé par les observations SMOS "parfaites" pour les sites du Niger et du Bénin pour les années 2010–2015. Les barres correspondent aux résultats de l'assimilation avec des observations SMOS "parfaites", les points bleus aux observations "parfaites" 730 obs. et les croix aux observations SMOS réelles. Les barres montrent bien une amélioration des scores lors de l'utilisation des observations SMOS "parfaites".

Lorsque l'on double la fréquence des observations "parfaites" on obtient les points bleus ; résultat important qui montre l'intérêt de la fréquence des données. On observe alors que le fait de doubler le nombre d'observations augmente au maximum de 25% le score observé.

Lors de l'utilisation des observations réelles de SMOS, on obtient les croix rouges. Ces croix montrent une correction "non-optimale" due aux erreurs associées aux observations SMOS.

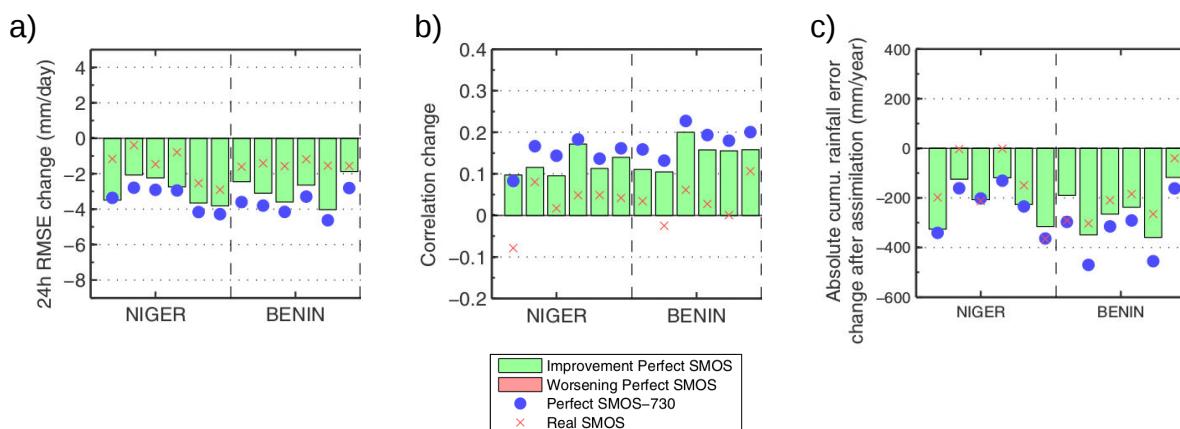


FIGURE 5.9 – a), b) et c) représentent le potentiel maximal qu'a le schéma d'assimilation à corriger les produits de précipitations CMORPHRAW. Les barres correspondent au cas de l'assimilation d'observations "parfaites", les points bleus lorsque ces observations sont optimisées en termes de fréquence de passage et les croix rouges sont le cas où les données SMOS réelles sont utilisées.

### 5.2.3.3 Limitations

Cette méthode ne permet pas de générer, ni de supprimer les événements de pluie, ce qui peut être problématique pour les fausses alertes (*false-alarm*) ou encore les événements de pluie manqués. Une autre limite survient cette fois-ci lorsque le taux d'humidité du sol est proche de la saturation ou sur les zones irriguées. En effet, l'irrigation augmente l'humidité dans le sol sans que cela ne soit lié aux événements de précipitations.

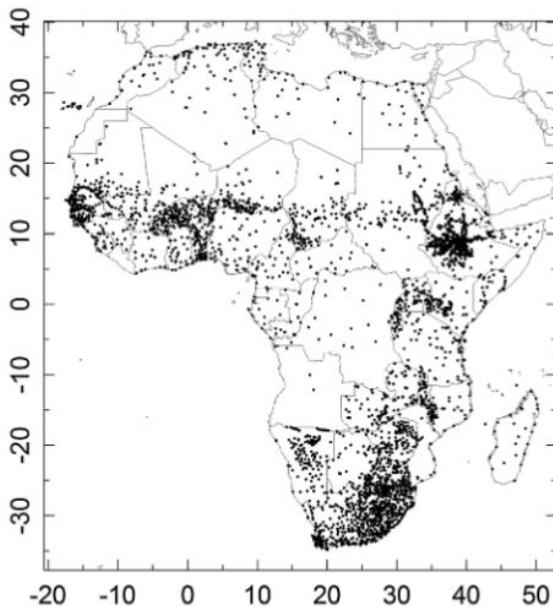
Les limites du modèle résident aussi dans les non-linéarités entre précipitations et humidité. Par exemple, lorsque l'humidité du sol est proche de la capacité d'infiltration du sol, l'augmentation d'un événement pluvieux sera plus faible que lorsque si le sol était plus sec. Ainsi, malgré les perturbations dépendantes de l'intensité des événements pluvieux (voir Figure 5.4), cela reste une limite forte.

## 5.3 Vers un produit haute résolution spatiale avec le produit TAMSAT

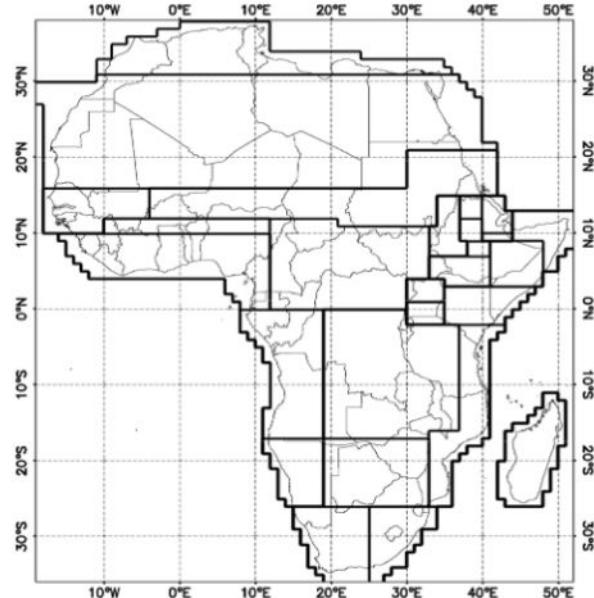
Maintenant que nous avons vu le potentiel de SMOS pour venir améliorer les produits de précipitations, intéressons-nous à la correction du produit TAMSAT.

### 5.3.1 Le produit de précipitation TAMSAT

TAMSAT est un produit de pluie utilisé par le centre régional AGRHYMET, en particulier pour suivre l'évolution des rendements agricoles. Il fait partie de ces produits répondant aux exigences de résolution spatiale  $0.0375^\circ \times 0.0375^\circ$  (soit 4 km x 4 km) et temporelle (journalier) nécessaire aux applications agricoles [Black et al., 2016]. Le principe d'estimation de la pluie utilisé par TAMSAT est basé sur l'observation de la température du sommet du nuage via la mesure du rayonnement infrarouge par le satellite MSG. Pour chaque pixel le calcul du "Cold Cloud Duration" (CCD) est effectué, correspondant au temps de présence du nuage froid dans le pixel. Ensuite, une calibration est effectuée entre la température, le temps de passage et la quantité de pluie mesurée par le réseau de pluviomètres Figure 5.10 a). Cette calibration permet de classifier certaines zones avec les mêmes paramètres Figure 5.10 b). Cependant, tout comme les produits de pluie satellitaires basse résolution ( $0.25^\circ$ ), TAMSAT capte assez bien les événements de pluie mais souffre d'incertitudes sur les quantités évaluées [Maidment et al., 2017].



(a) Carte des pluviomètres utilisés pour la calibration de TAMSAT.



(b) Carte des zones climatiques ayant les même coefficients.

FIGURE 5.10 – Données terrains utilisées dans la calibration du produit TAMSAT [Maidment et al., 2017].

### 5.3.2 Détail de la chaîne de traitement

La chaîne de traitement qui permet la correction du produit TAMSAT est décrite par le synoptique Figure 5.11. Le principe est de transformer la résolution spatiale et temporelle du produit TAMSAT au format compatible pour la méthode d'assimilation décrite [Partie 3.5.1](#), étapes 1 à 3. Puis, les étapes 4 et 5 ont pour rôle de ramener TAMSAT à sa résolution d'origine.

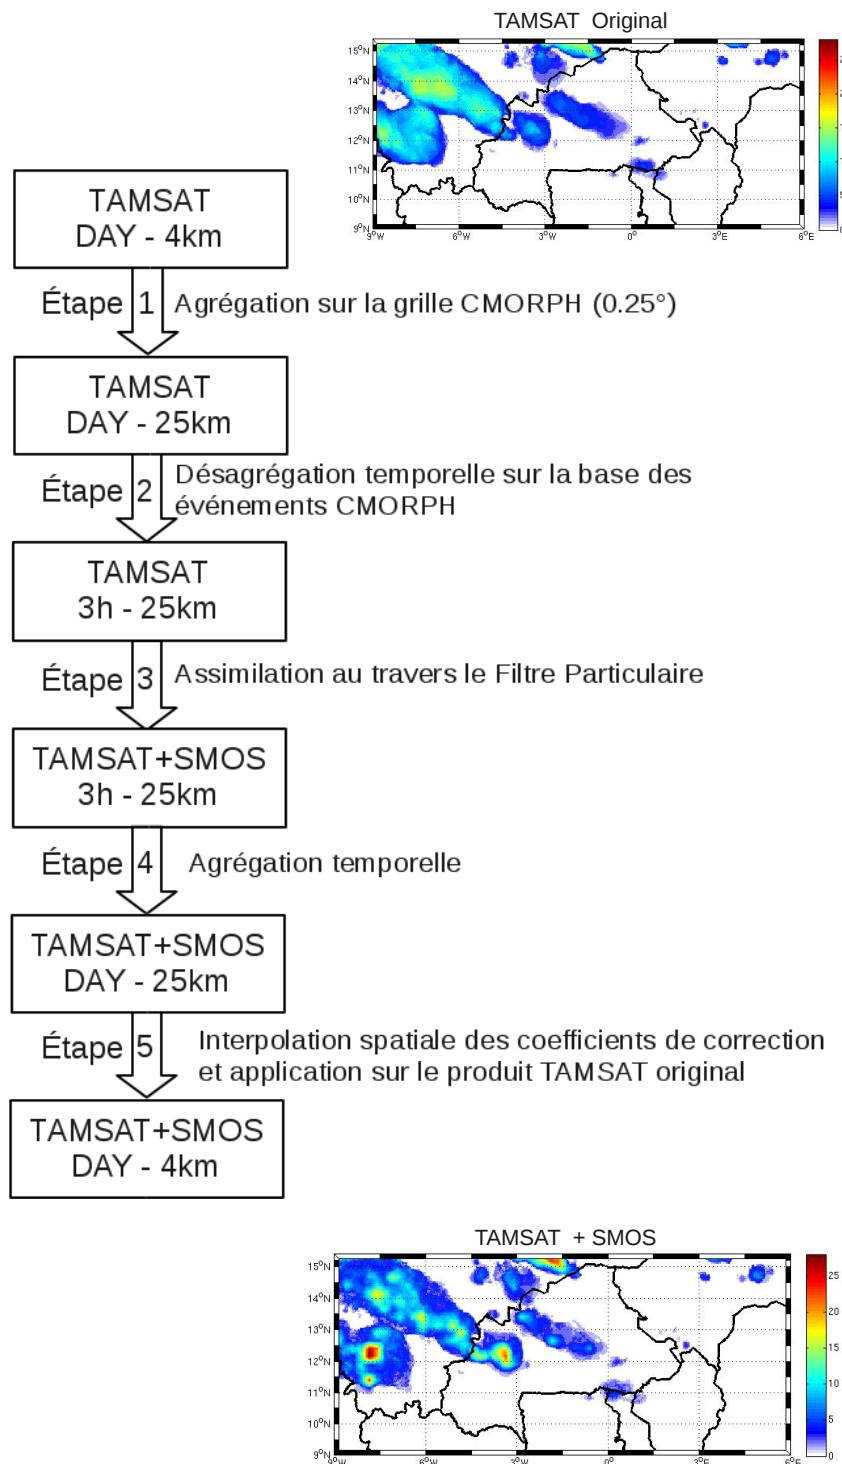


FIGURE 5.11 – Chaîne de traitement pour la correction de TAMSAT par SMOS.

### 5.3. VERS UN PRODUIT HAUTE RÉSOLUTION SPATIALE AVEC LE PRODUIT TAMSAT

Détaillons maintenant chacune de ces étapes :

- **Étape 1 :**

Cette première étape a pour objectif de désagréger spatialement TAMSAT  $0.0375^{\circ}$  sur la grille de CMORPH  $0.25^{\circ}$ . Pour cela, on calcule la moyenne des pixels TAMSAT compris dans une maille de la grille CMORPH, comme sur la Figure 5.12 :

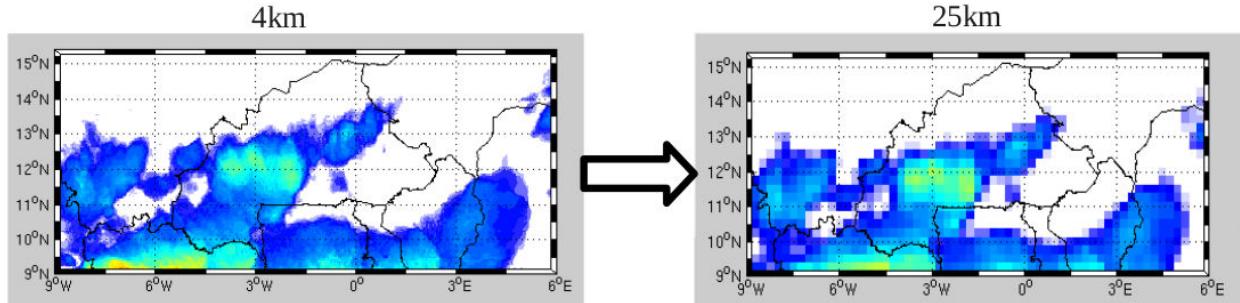


FIGURE 5.12 – Agrégation spatiale du produit TAMSAT.

- **Étape 2 :**

Cette seconde étape a pour objectif de désagréger temporellement TAMSAT, de 24 h à 3 h. Pour cela nous utiliserons ici la dynamique temporelle (3 h) des précipitations fournie par CMORPH. La distribution normalisée des événements CMORPH contenus dans un pas de temps TAMSAT est multipliée par l'intensité de ce dernier. La Figure 5.13 représente cette opération. Les barres transparentes sont les événements CMORPH. Lorsqu'elles se trouvent dans un événement TAMSAT, elles sont normalisées, première partie de l'équation (5.3), puis multipliées par la valeur de la barre bleue.

$$TAMSAT_{25km/3h} = \frac{CMORPH_{25km/3h}}{\sum_{i=6h}^{6h+24h} CMORPH_{25km/3h}} \times TAMSAT_{25km/24h} \quad (5.3)$$

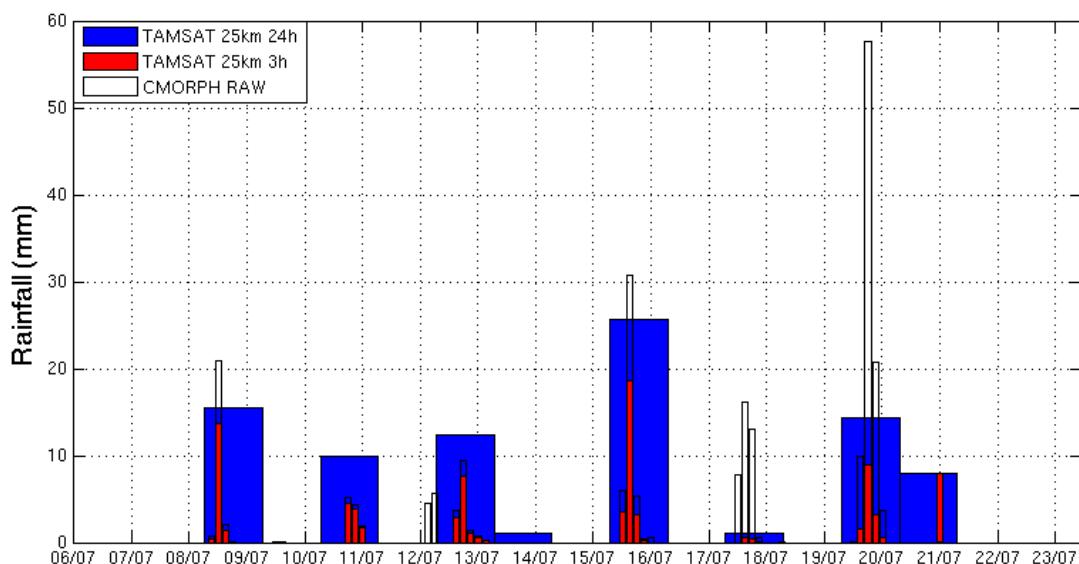


FIGURE 5.13 – Désagrégation temporelle de TAMSAT, de 24 h à 3 h en utilisant la temporalité de CMORPH.

## 5.3. VERS UN PRODUIT HAUTE RÉSOLUTION SPATIALE AVEC LE PRODUIT TAMSAT

- **Étape 3 :**

Maintenant que le produit TAMSAT est au format des précipitations utilisées dans le schéma d'assimilation développé [Chapitre 3](#), c'est-à-dire ( $0.25^\circ$ , 3 h). La méthode de correction à partir des données SMOS est ensuite appliquée et le résultat est un produit TAMSAT corrigé à  $0.25^\circ$  et 3 h.

- **Étape 4 :**

Cette étape revient à repasser à la résolution de 24 h, de manière à se remettre au format original de TAMSAT. Pour cela le produit est agrégé de 6h à 6h.

- **Étape 5 :**

Cette étape concerne la désagrégation spatiale du produit de pluie après assimilation, pour le passer de  $0.25^\circ$  à  $0.0375^\circ$ . Pour cela une division du produit avant et après assimilation fournit une information sur la potentielle augmentation, ou diminution, dans le pixel de  $0.25 \times 0.25^\circ$ . Sur la carte du haut, Figure 5.14, le rapport entre le produit juste avant et après l'étape d'assimilation est représenté (cumul de l'année 2010). On retrouve en rouge les zones où globalement la pluie a été augmentée et en bleu où elle a été diminuée.

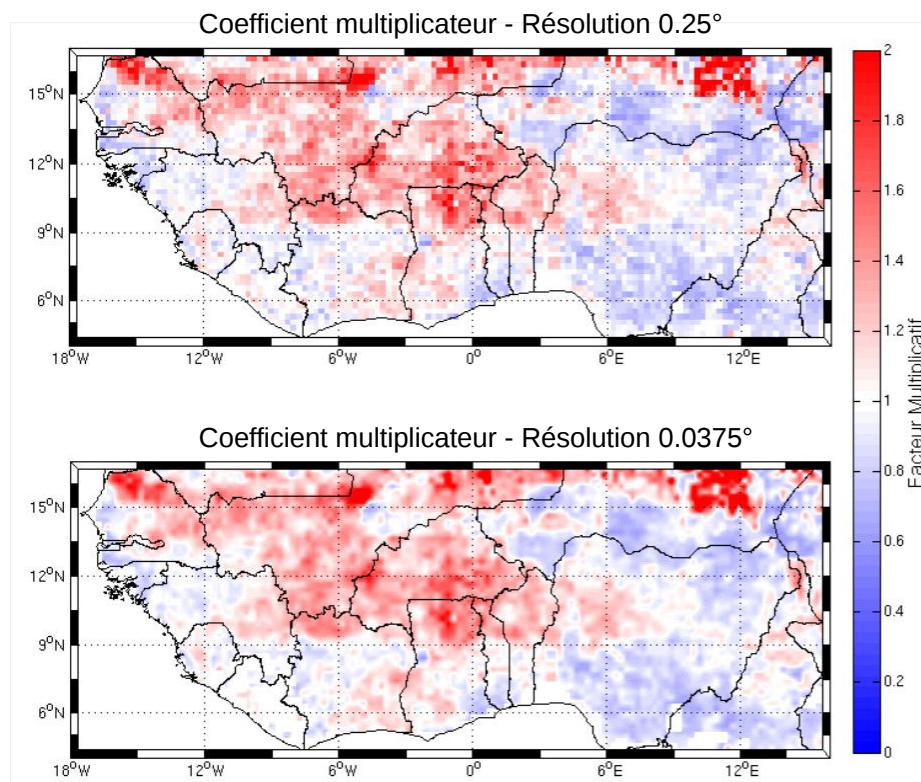


FIGURE 5.14 – Interpolation des cartes de coefficient multiplicateur ( $0.25^\circ$  figure du haut et  $0.0375^\circ$  (résolution TAMSAT Original) figure du bas), année 2010.

### 5.3.3 Résultats et discussion

Afin d'évaluer l'apport de l'assimilation de données de SMOS dans le produit de précipitation satellite TAMSAT, comparons-le avec différents jeux de données de précipitations de référence. Tout d'abord à l'échelle locale, puis à l'échelle du continent africain.

#### 5.3.3.1 Évaluation locale

La position des pluviomètres utilisés pour la validation des produits de précipitations TAMSAT, avant et après assimilation est représentée Figure 5.15. Ce réseau est composé du réseau de pluviomètres AMMA-CATCH pour le Bénin et le Niger, et du réseau AGRHYMET pour le Burkina Faso.

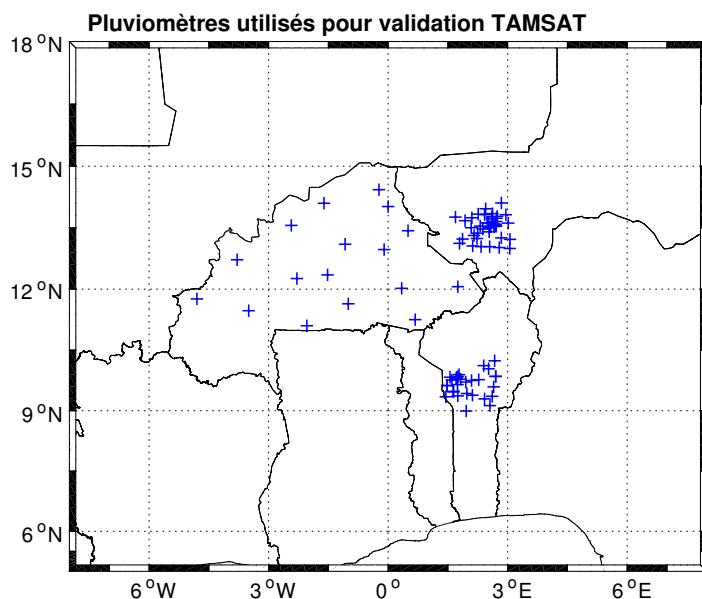


FIGURE 5.15 – Réseau de pluviomètres utilisés dans l'évaluation du produit TAMSAT et TAMSAT corrigé.

Ces pluviomètres fournissent des informations horaires sur les précipitations. Ces données vont donc servir de référence pour une évaluation locale en échantillonnant le produit TAMSAT avant et après assimilation sur les différents points des pluviomètres (croix de la Figure 5.15). Afin d'évaluer l'apport de l'assimilation de SMOS dans TAMSAT, observons les différences de cumuls annuels pour les trois pays. La Figure 5.16 représente en noir la moyenne des pluviomètres pour le Bénin (figure du haut), le Niger (figure du milieu) et le Burkina Faso (figure du bas). Sur chaque figure sont représentées les moyennes des sondes *in-situ* (en noir avec l'enveloppe), les pluies TAMSAT avant assimilation (en vert) et après assimilation (en rouge).

Sur la Figure 5.16 on peut observer l'impact de l'assimilation par site d'étude en termes de cumul. L'objectif étant de se rapprocher des courbes noires, correspondant aux mesures *in-situ*. Pour le site du Bénin, l'assimilation est très efficace pour l'année 2012 et améliore plus légèrement pour les autres années. Pour le site du Niger, l'assimilation semble dégrader le produit pour l'année 2010, pour les autres années elle l'améliore. Pour le site du Burkina Faso, les résultats sont très bons sauf en 2011 où l'effet semble relativement faible.

### 5.3. VERS UN PRODUIT HAUTE RÉSOLUTION SPATIALE AVEC LE PRODUIT TAMSAT

---

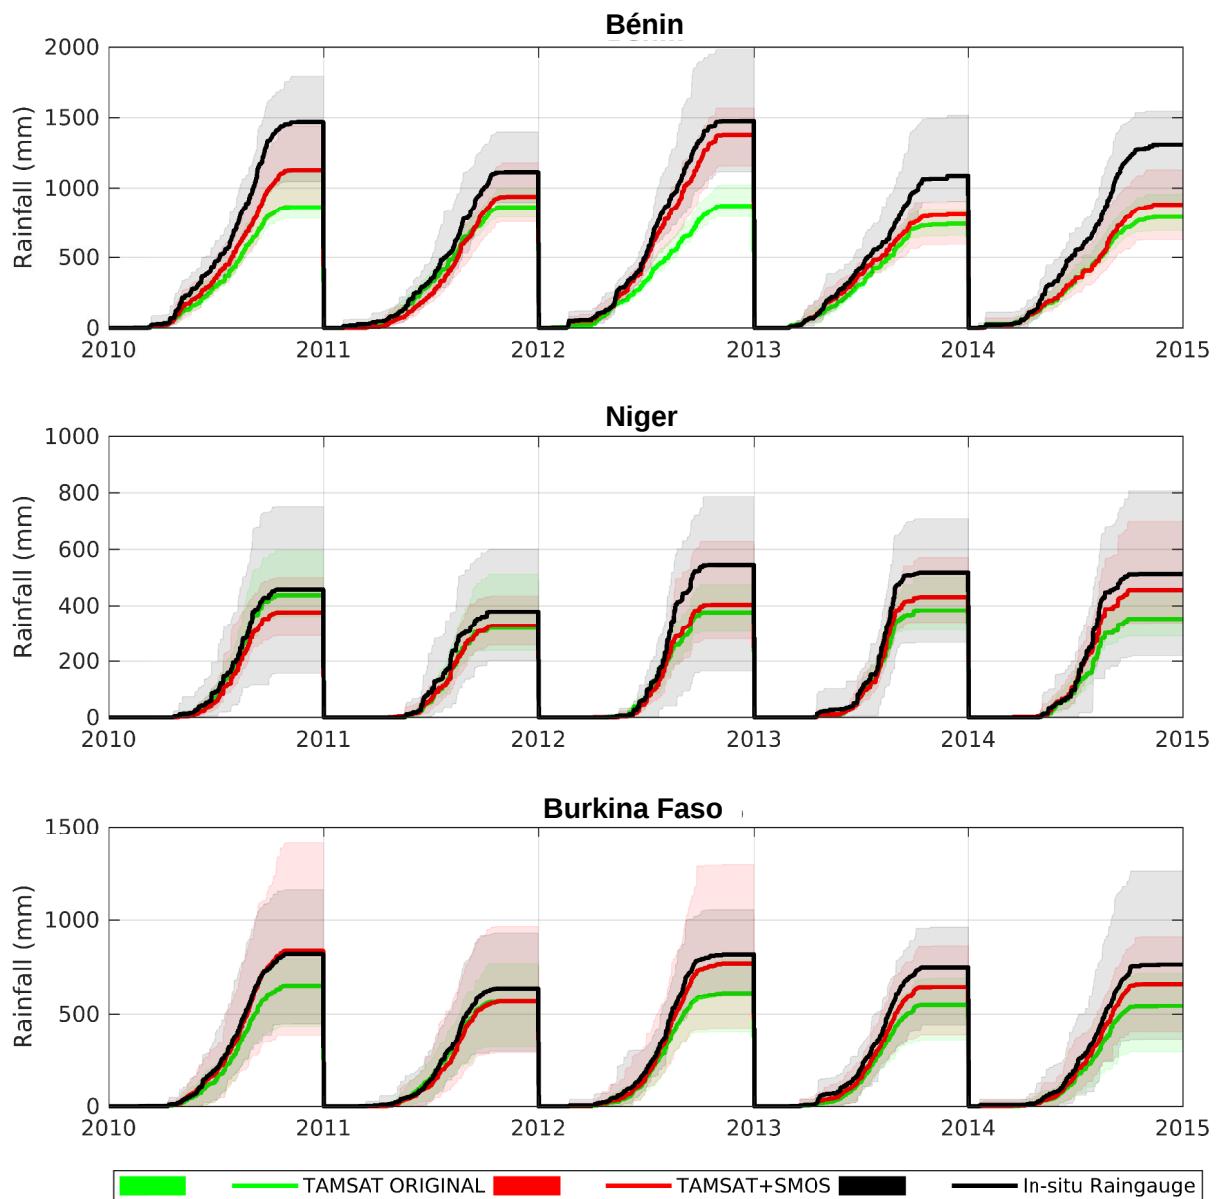


FIGURE 5.16 – Comparaison des cumuls annuels par région (moyenne et enveloppe des pluviomètres par pays) à partir des pluviomètres en noir, de TAMSAT Original en vert et après assimilation en rouge.

Afin de mieux quantifier l'apport de l'assimilation, utilisons les scores de moyenne de RMSE sur l'année, de biais annuel et de corrélation entre les points TAMSAT correspondant au différents pluviomètres.

### 5.3. VERS UN PRODUIT HAUTE RÉSOLUTION SPATIALE AVEC LE PRODUIT TAMSAT

La Figure 5.17 présente les scores avant/après assimilation pour les deux sites respectifs du Bénin et du Niger, pour toutes les stations pluviométriques. Les résultats sont présentés sous la forme de différences de scores entre le produit après assimilation et le produit original, pour les années 2010–2014 pour les trois sites de mesures (sous forme de boîtes à moustaches afin de représenter l'ensemble des stations).

Les différences de corrélation sont présentées sur la première ligne. On remarque que l'ensemble des années, sur tous les sites, affiche une amélioration significative de la corrélation (entre +0.1 et +0.25 point de corrélation), sauf pour l'année 2011 pour les sites du Bénin et du Niger (probable erreur dans la base de données...).

Les différences de RMSE journaliers sont elles aussi globalement positives avec une amélioration des scores allant jusqu'à -1 mm/jour d'erreur pour les sites du Bénin et du Niger (on notera toujours l'année 2011 qui semble dégradée). Pour le Burkina Faso l'effet semble assez faible. Les différences de biais annuel sont globalement négatives, signifiant que le biais est réduit après assimilation. On remarque que pour le Bénin, les biais sont réduits entre -50 et -350 mm/an. Pour le Niger et le Burkina, de par leur pluviométrie globalement plus faible, les valeurs sont donc plus faibles, de +20 (pour l'année 2011...) à -100 mm/an.

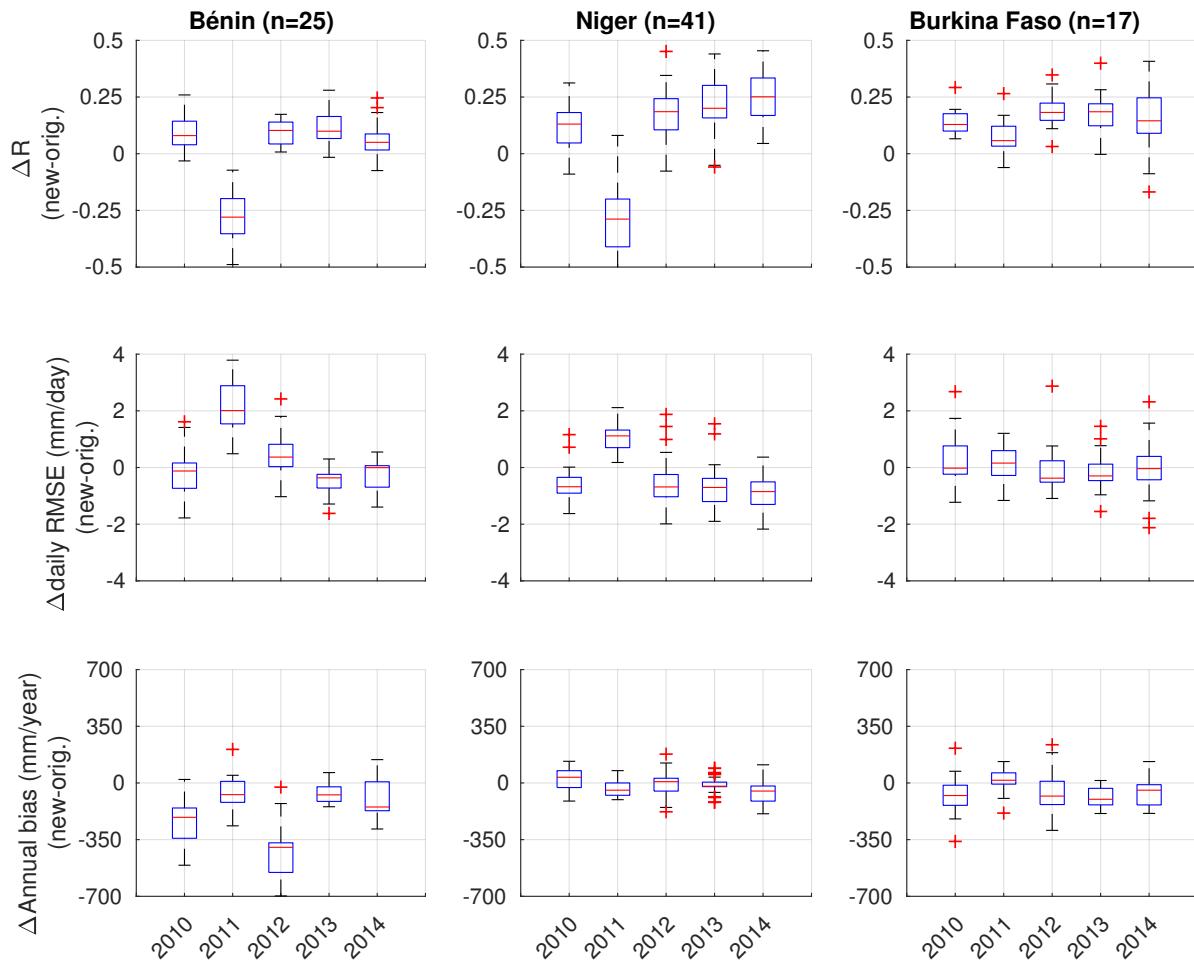


FIGURE 5.17 – Évaluation de TAMSAT avant/après assimilation, pour les années 2010–2014, en termes de différence de corrélation, de différence de RMSE et de biais annuel, pour les sites du Bénin, du Niger et du Burkina Faso.

### 5.3. VERS UN PRODUIT HAUTE RÉSOLUTION SPATIALE AVEC LE PRODUIT TAMSAT

On peut aussi observer l'apport de l'assimilation sur la distribution spatiale des précipitations en observant les champs de pluie avant et après assimilation. La Figure 5.18 montre un champ de pluie journalier par le produit TAMSAT Original (haut) et après assimilation par SMOS (bas). On observe alors une augmentation de la variabilité spatiale des champs de pluie.

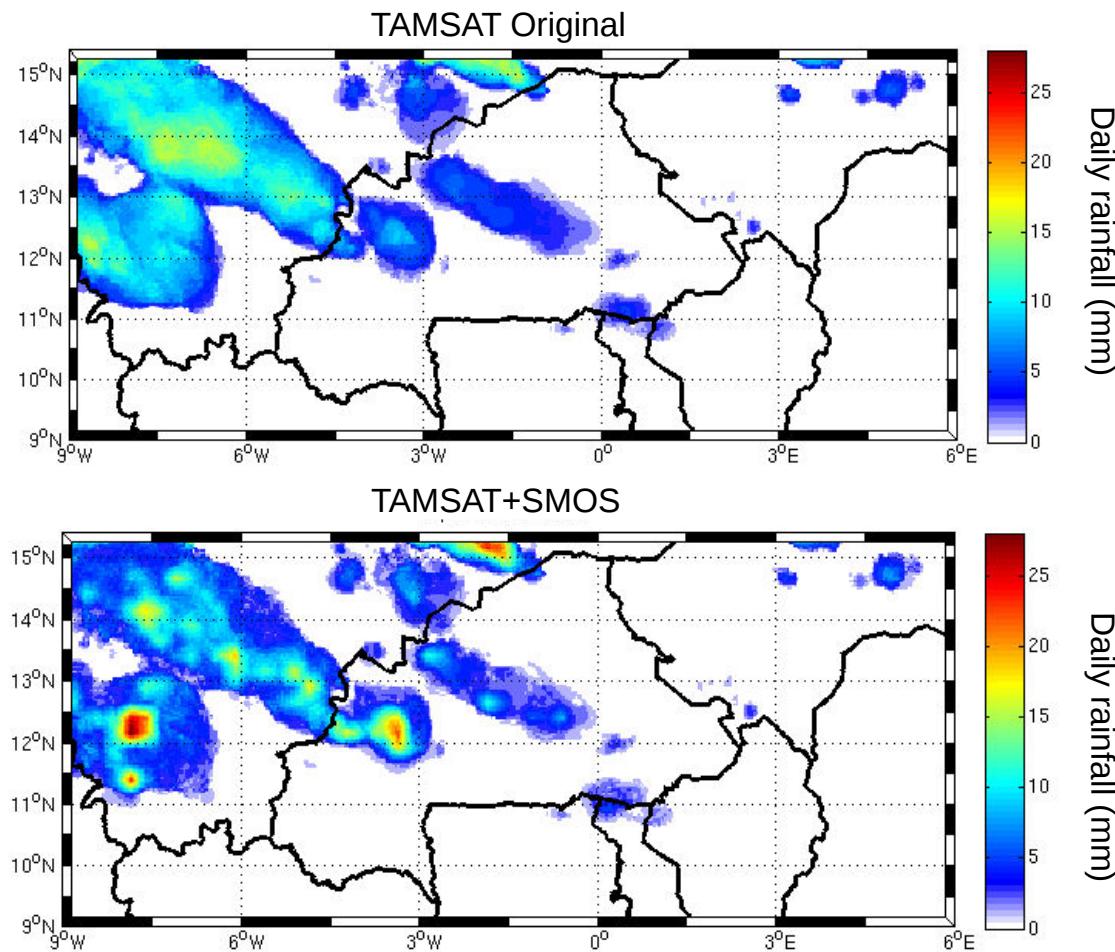
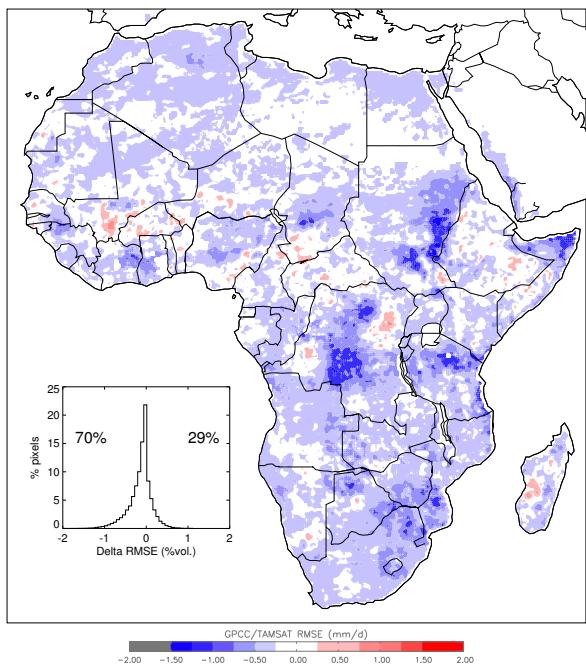


FIGURE 5.18 – Impact spatial de l'assimilation de SMOS dans TAMSAT, le 10 juillet 2010.

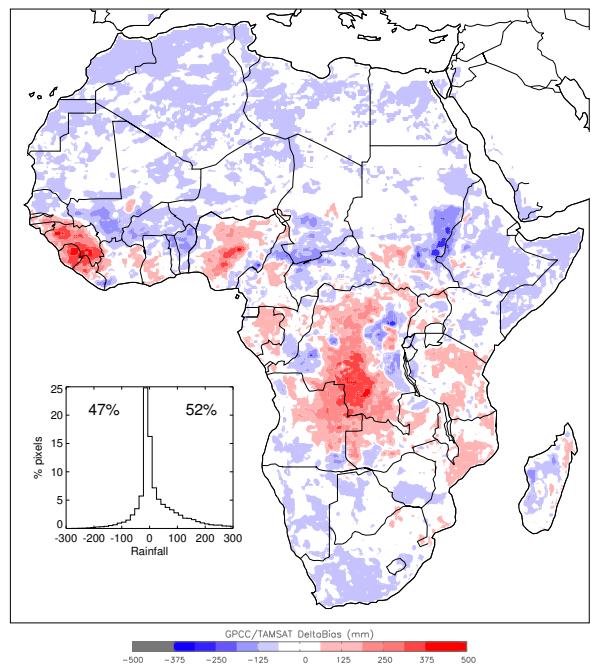
Le champ de pluie observé par TAMSAT à travers son observation infrarouge ne fait état que du "potentiel" pluvieux de ce dernier. En ajoutant l'information des variations d'humidité du sol fournie par SMOS au travers l'assimilation il est possible d'apporter l'information de ce qui est "réellement" tombé au sol. Cependant il est difficile d'évaluer spatialement l'apport de l'assimilation.

### 5.3.3.2 Évaluation à l'échelle du continent africain

Afin d'évaluer l'apport de l'assimilation à l'échelle globale, les produits TAMSAT avant et après assimilation sont comparés au produit Global Precipitation Climatology Center (GPCC) [Huffman et al., 2001]. Ce produit, GPCC, d'une résolution spatiale de  $1^\circ \times 1^\circ$ , et temporelle de 1 jour, est constant à partir de la spatialisation des champs de pluies mesurés par des pluviomètres. Les Figures 5.19 a) et 5.19 b) représentent respectivement les différences de scores de RMSE journalier et de biais annuel, avant et après assimilation.



(a) Différences de RMSE entre TAMSAT/GPCC et TAMSAT<sub>SMOS</sub>/GPCC.



(b) Différences de cumul annuel entre TAMSAT/GPCC et TAMSAT<sub>SMOS</sub>/GPCC.

FIGURE 5.19 – Évaluation de l'assimilation de SMOS dans TAMSAT à l'échelle globale.

Sur la Figure 5.19 a) est représentée la différence de RMSE journalier entre TAMSAT sans assimilation et TAMSAT après assimilation, en référence à GPCC. En bleu quand l'assimilation diminue le RMSE et en rouge quand elle l'augmente. On remarque alors que le RMSE diminue fortement en Afrique centrale et à l'est du Soudan (entre -1 et -1.5 mm/jour). L'histogramme montre que 70% des pixels ont leur RSME journalier diminué et 29% augmenté.

Sur la Figure 5.19 b) est représentée la différence de cumul annuel entre TAMSAT sans assimilation et TAMSAT après assimilation, en référence à GPCC. En bleu quand l'assimilation diminue la différence de cumul annuel et en rouge quand elle l'augmente. On remarque alors que l'assimilation augmente fortement le biais sur la côte guinéenne, le Nigeria et au sud de la République démocratique du Congo. Globalement, 52% des pixels ont vu leur biais augmenter après assimilation et 47% l'ont vu diminuer.

### 5.3. VERS UN PRODUIT HAUTE RÉSOLUTION SPATIALE AVEC LE PRODUIT TAMSAT

Une explication potentielle de cette détérioration du biais après assimilation de SMOS (zone rouge Figure 5.19 b)) réside dans la présence de forêt dense. En effet, la présence de végétation augmente l'incertitude des mesures SMOS et, par conséquent, détériore la qualité des corrections des précipitations. Une autre explication pourrait venir de la faible densité du réseau de pluviomètres sur ces régions. En effet, le produit de référence, GPCC, est uniquement basé sur des réseaux de pluviomètres. Or, le réseau en Afrique est relativement faible, comme représenté Figure 5.20. Sur cette Figure, représentant le nombre de pluviomètres par maille de  $1^{\circ} \times 1^{\circ}$  utilisé en juin/juillet/août 2017, on observe que la densité du réseau est particulièrement faible sur les zones de grande différence de cumul Figure 5.19 b).

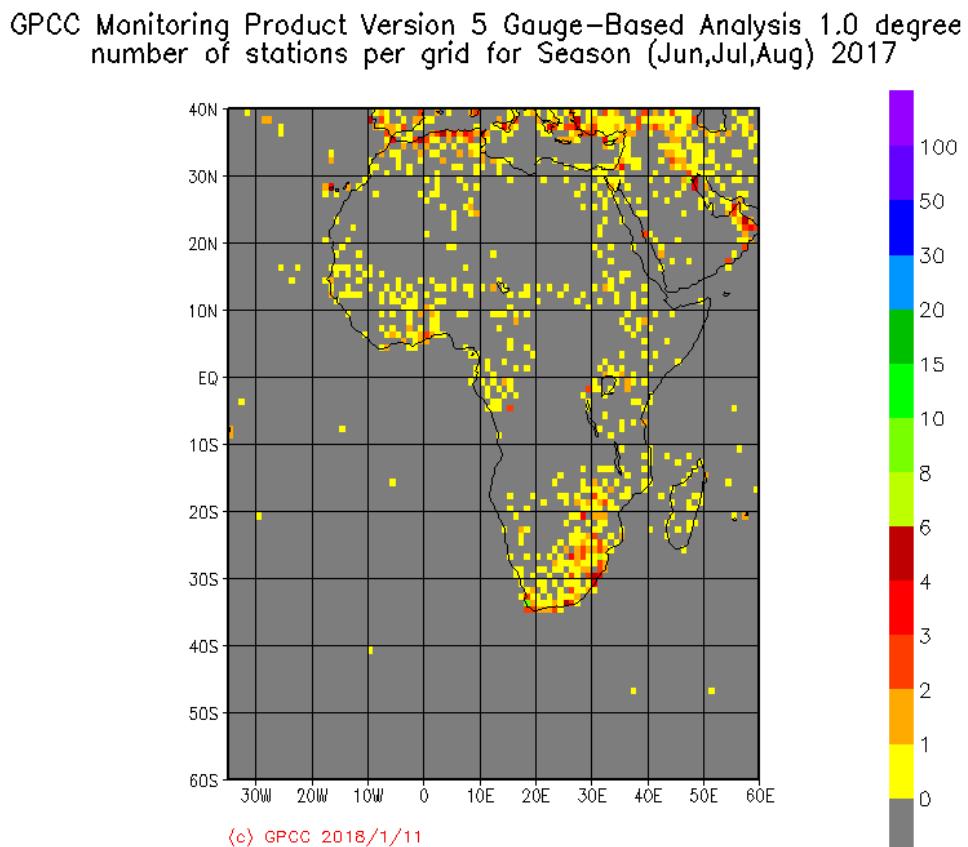


FIGURE 5.20 – Nombre de pluviomètres utilisés dans GPCC, contenus dans une grille de  $1^{\circ}$  pendant juin/juillet/août 2017.

## 5.4 Résumé et conclusion

L'estimation des précipitations à large échelle en temps-réel est critique pour les applications hydrologiques opérationnelles (prévision des crues, glissements de terrain,...) ainsi qu'agronomique (alertes précoce sur la production, qualité des cultures,...). Cependant, la qualité de ces dernières rend leur utilisation complexe car très incertaine. À partir du schéma d'assimilation basé sur le Filtre Particulaire, il a été montré que les précipitations pouvaient être corrigées en utilisant les données SMOS. Les résultats montrent une forte amélioration des scores. De plus, les expériences d'assimilation avec les données synthétiques ont montré que le caractère ensembliste du schéma ne dégradait pas substantiellement les données initiales (+0.2 mm/day de RMSE pour 40 membres sélectionnés). Elles ont aussi montré que l'augmentation du nombre de données assimilées était un facteur important et permettait d'améliorer encore l'assimilation (de +0 à +25% sur les scores lorsque la fréquence est doublée). Cela s'intègre clairement dans l'utilisation future des données du satellite SMAP.

Cette méthode a ensuite été utilisée pour corriger un produit de précipitation destiné à des applications agronomique, TAMSAT. La comparaison avec des réseaux de pluviomètres au Bénin, au Burkina Faso et au Niger montre une amélioration (sauf pour 2011) de la corrélation (entre +0 et +0.25), du RMSE journalier (entre -0 et -1 mm/jour) et du biais annuel, sur les trois sites. D'un point de vue spatial, l'apport de SMOS semble intéressant car il redonne de la dynamique spatiale aux structures de systèmes précipitant, cependant il est difficile de quantifier la qualité de cet apport.

Les évaluations à l'échelle globale montrent que 70% des pixels se rapprochent de la référence utilisée, GPCC. Cependant, la densité du réseau utilisé dans GPCC et la présence de forêt modère la qualité de ces résultats. L'une des solutions utilisées ici est de se baser directement sur les pluviomètres.



# Conclusion Générale

L'humidité du sol a été déclarée comme variable essentielle du climat (*Essential Climate Variable*, ECV) en 2010 par l'Agence spatiale européenne (ESA), en support du travail du Groupe d'experts Intergouvernemental sur l'Évolution du Climat (GIEC). Cette infime proportion du cycle de l'eau (0.005% du total des réservoirs de l'hydrosphère) agit en effet sur le fonctionnement de la biosphère (en conditionnant le développement de la végétation, l'évapotranspiration,...) ainsi que sur de nombreux processus hydrologiques (ruissellement de surface, recharge des aquifères, maintien du débit d'étiage,...). Dans les climats arides et semi-arides, comme en Afrique de l'Ouest, les impacts des variations d'humidité du sol sont d'autant plus forts qu'ils sont souvent facteurs limitants de processus comme la croissance végétale (dont la production fourragère et céréalière).

L'observation est un élément fondamental pour comprendre et caractériser les variations des grands processus en changement dans notre environnement. L'arrivée de l'observation de la Terre par satellite a permis d'apporter de nombreuses informations dans de nombreux domaines différents. Dans le domaine du suivi des cultures agricoles, les produits de précipitations, d'indices d'activités photosynthétiques, de température de surface ou encore de surface foliaire, permettent aujourd'hui de suivre, avec plus ou moins de succès, l'évolution de la végétation. Cependant, très peu d'études se sont intéressées à l'apport de l'humidité du sol pour l'estimation des rendements. La raison principale est liée à l'absence de mesures suffisamment précises de cette variable jusqu'au lancement en 2009 de la première mission spatiale spécifiquement dédiée à la mesure de l'humidité du sol : la mission SMOS.

Le premier objectif de ce travail de dissertation a été d'évaluer différentes méthodes d'estimations de l'humidité du sol afin d'aborder la problématique :

**Comment estimer l'humidité du sol en Afrique de l'Ouest ?**

Le [Chapitre 1](#) de la thèse a été consacré à définir l'humidité du sol et les différents moyens de l'estimer à partir de sondes de terrain (*in-situ*), de données satellites ou par l'intermédiaire d'un modèle numérique. Dans le [Chapitre 2](#), les mesures d'humidité *in-situ* issues de l'observatoire AMMA-CATCH ont été analysées. Ces données permettent de représenter les variations d'humidité jusqu'à 1 m de profondeur sur 2 sites, au Bénin et au Niger. Les profils d'humidités ont montré une infiltration systématique de l'eau à plus de 1 m au Bénin, alors qu'au Niger, les années 2010 et 2011 montrent une profondeur d'infiltration atteignant difficilement 1 m. Néanmoins, la densité du réseau de mesures est trop faible pour une représentation spatialisée. Une des solutions réside dans l'utilisation de méthodes à "grande échelle" comme la télédétection avec SMOS ou les modèles de surface.

Le satellite SMOS permet de faire des estimations d'humidité superficielle des sols (typiquement  $\sim 5$  cm) avec une résolution de 25 par 25 km ( $0.25 \times 0.25^\circ$ ). Les mesures SMOS ont été comparées aux mesures *in-situ* et montrent une bonne qualité de la variabilité de l'humidité (ubRMSE de  $0.07 \text{ m}^3 \cdot \text{m}^{-3}$  pour le Bénin et  $0.04 \text{ m}^3 \cdot \text{m}^{-3}$  pour le Niger). Cependant, la profondeur estimée, l'impact des interférences (RFI) ou encore la fréquence de revisite limitent l'utilisation directe de ce produit.

La dernière méthode qui fut étudiée ici est la modélisation de surface. L'humidité du sol a été simulée à différentes profondeurs à l'aide de 2 modèles, de niveaux de complexités différents : le modèle API et le schéma de surface SURFEX. La qualité des simulations montrent des estimations de bonne qualité dans les 50 premiers centimètres du sol lorsque les modèles sont forcés par des pluies issues de pluviomètres. Cependant, comme pour les mesures *in-situ* d'humidité du sol, le réseau de pluviomètres n'est pas suffisant pour représenter la grande variabilité spatiale des précipitations. L'utilisation de produits satellitaires de pluie est donc nécessaire pour alimenter ces 2 modèles. La qualité des produits de précipitations dans leur version temps-réel ont montré des limites à la modélisation correcte de la dynamique de l'humidité du sol sur les sites du Niger et du Bénin. C'est pourquoi dans le [Chapitre 3](#), des méthodes d'intégration des données satellites SMOS dans les 2 modèles de surface ont été étudiées via l'assimilation de données. Il en a résulté une méthode (filtre particulaire) permettant de corriger en amont les incertitudes sur les précipitations de manière à améliorer les simulations d'humidité.

Le [Chapitre 4](#) a été consacré à l'étude du lien entre l'humidité du sol et le rendement des cultures de mil au Sahel afin d'apporter des éléments de réponse à la problématique :

**Quel est le potentiel des variations d'humidité du sol à expliquer les variations de rendements agricole en Afrique de l'Ouest ?**

Une étude réalisée à l'échelle locale (10 villages situés dans la région de Niamey au Niger) a permis de mettre en évidence le rôle important du taux d'humidité du sol à 30 cm de profondeur pendant 2 périodes du développement de la plante : la période reproductive (mois de juillet) et la période de remplissage des grains (de fin août à mi-septembre). L'étude a montré que la moyenne des anomalies d'humidités sur les 2 périodes, pour les 9 villages permet d'expliquer 77% des variations de rendements moyens de ces villages.

Cette relation a ensuite été extrapolée à l'échelle nationale du Niger. Pour cela, des cartes d'humidité du sol à 30 cm ont été calculées (dérivées des méthodes décrites [Chapitre 2](#) et [Chapitre 3](#)). Les anomalies d'humidité sur les 2 périodes identifiées à l'échelle locale ont permis d'expliquer 62% de la variation des rendements fournis par la FAO pour le Niger pour les années 1998–2012.

Cette relation a ensuite été appliquée à la bande sahélienne. La relation entre humidité du sol à 30 cm sur les 2 périodes explique 76% de la variation de rendement sur les pays du Niger, Burkina, Mali et Sénégal pour les années 1998–2014. À partir de cette relation, un modèle rendement/humidité a été établi et appliqué afin de dériver des cartes de rendement. La comparaison entre les rendements estimés sur l'ensemble des pays et les données de la FAO montre un  $R^2$  de 0.77, et, malgré le manque de points de validation, la distribution spatiale des rendements retrouvés a potentiellement une valeur ajoutée importante dans un cadre opérationnel.

Enfin dans le [Chapitre 5](#), la dernière problématique est abordée :

**Comment améliorer l'estimation des précipitations par satellite à partir des observations d'humidité du sol SMOS ?.**

Dans ce dernier chapitre, le potentiel correctif de la méthode d'assimilation développée au [Chapitre 3](#) est analysée. Les résultats montrent une correction des précipitations de l'ordre de -2 mm/jour de RMSE par rapport à des pluviomètres sol. L'expérience synthétique a aussi montré que doubler le nombre d'observations assimilées permettrait d'augmenter les scores de +25%.

Cette méthode a ensuite été appliquée au produit TAMSAT. Ce produit haute résolution (4 km x 4 km), fait partie des produits utilisés en opérationnel par les agences de suivi agricole pour effectuer des diagnostics de déficit hydrique à destination des décisionnaires. Le produit de pluie a subi tout d'abord un traitement, de manière à le rendre compatible avec les résolutions spatiale et temporelle du schéma d'assimilation, puis il a été évalué.

## 5.4. RÉSUMÉ ET CONCLUSION

---

L'évaluation locale, basée sur un réseau de pluviomètres (au Niger, au Bénin et au Burkina Faso) a été effectuée. Les résultats montrent une amélioration (entre -0 et -2 mm/jour de RMSE) du produit TAMSAT après assimilation pour les sites du Bénin, du Niger et du Burkina Faso. Enfin, une dernière évaluation à l'échelle du continent africain, à partir du produit de pluie de référence GPCC, montre une amélioration générale du RMSE journalier dans 2/3 des cas. Cependant le produit de référence souffre de grandes incertitudes de par la répartition des pluviomètres sur lesquels il est basé. L'apport de l'assimilation sur la distribution spatiale du produit peut donc être difficilement validée.



# Perspectives

Le niveau de résilience des sociétés est un facteur fondamental pour le futur de l'Humanité. L'évolution du climat dans les années futures modifiera nos modes de vie de manière plus ou moins importante en fonction de notre situation géographique, économique, sociale,... Certaines régions du monde sont cependant pressenties comme plus "vulnérables" que d'autres pour des raisons multifactorielles (climat extrême, croissance démographique, accès à l'eau potable,...) ; la région du Sahel en fait partie. Les recherches interdisciplinaires dans ces régions sont particulièrement sensibles dans le contexte de changement climatique. Or, ces recherches sont fortement dépendantes de données, et donc d'observations.

Globalement le développement de moyens d'observation est fondamental pour alimenter les réflexions sur les changements futurs. Cependant, l'intérêt des satellites d'observations ou des modèles numériques est très faible si les réseaux de mesure *in situ* ne sont pas développés et maintenus de manière pérenne. En effet, ces données de mesures servent couramment de référentiel aux autres moyens d'observations. D'un autre côté, de fortes limites, telles que leur faible représentativité spatiale ou leur coût de maintenance élevé (économique et main d'oeuvre), leur portent fortement préjudice. Les autres moyens d'observation ou de modélisation dépendant de ces données, la forte interdépendance du triptyque insitu/modélisation/télédétection est telle que leur développement doit s'effectuer de manière homogène et de manière pérenne.

Le nombre de satellites d'observation de la Terre ne cesse de croître, de 120 en 2011, les estimations donnent 250 en 2020 (données Euroconsult). Le développement des capteurs démultiplie considérablement le potentiel des applications envisageables dans le futur. Face à ce volume croissant de données, le développement de méthodes numériques pour le traitement du Big Data est devenu le nouveau paradigme de la télédétection. Or, la question du traitement de ces dernières est fondamentale. En effet la différence de vitesse entre le traitement (analyse, recherche, interprétation et utilisation) et la production de ces données est très grande. Il faut donc être très attentif au maintien de la cohérence entre ces données et les recherches en sciences de la Terre. L'analogie avec la modélisation, est assez claire dans le cadre de l'utilisation de méthodes de calcul de plus en plus performantes pour des modèles de plus en plus complexes.

Un point important est le développement interdisciplinaire de la synergie entre triptyque insitu/modélisation/télédétection via l'assimilation. Les méthodes mathématiques couplées aux développements informatiques dans le cadre de recherche en géosciences permettent de produire des données à très forte valeur ajoutée.

Cette étude montre qu'il y a un grand potentiel d'exploitation des données et des méthodes déjà existantes. Voici pour chaque thématique abordée dans ces travaux, des pistes de réflexions pour les poursuivre :

### Mesures *in-situ*

- Il serait intéressant de refaire les calibrations des sondes avec des échantillons de sol pour différencier l'origine des biais entre les sondes (textures du sol ?, de la modification de la profondeur ?).
- L'analyse de tendance (avec au moins 10 ans de données) à partir des données *in-situ* permettrait de contribuer à l'étude des changements de régime de précipitations en cours dans cette région.
- Dans une optique d'étudier l'infiltration de l'eau sur les sites du Bénin et du Niger, il serait intéressant de coupler les données à des données de tensiomètres et d'analyser l'impact de l'humidité sur les recharges de nappes.
- La profondeur du front d'humectation modifie l'infiltration de l'eau tout au long de la saison des pluies. Les séries d'humidité à différentes profondeurs permettent de visualiser ce front. Une analyse de l'évolution interannuelle de la position du front d'humectation serait intéressant.

### Télédétection

- Un nouveau satellite dédié à l'humidité du sol, SMAP, a été lancé en 2015, l'utilisation de ses données fait partie des perspectives de ces travaux.
- Pour les produits SMOS, 2 nouveaux algorithmes sont en développement : SMOS-IC (avec un nouveau modèle d'inversion voir [[Fernandez-Moran et al., 2017](#)]) et SMOS-nn (avec un réseau de neurones, voir [[Rodriguez-Fernandez et al., 2014](#)]).
- La synergie entre les satellites dédiés à l'humidité du sol, SMOS et SMAP devrait montrer aussi un grand potentiel.

### Modélisation

- L'utilisation d'un modèle statistique "simple" semble assez bien adaptée aux échelles de la télédétection micro-onde. Cependant, ces travaux ont montré que le filtre utilisé pour propager l'information en profondeur avait des limites, surtout au niveau de la quantité d'eau infiltrée. Investiguer la modélisation de cette infiltration en utilisant les données *in-situ* comme support serait intéressant.
- Le développement de modèles à base physique haute résolution, type Parflow-CLM, semble très prometteur dans le cadre d'une synergie avec des produits satellites.

### Assimilation

- Il serait intéressant d'utiliser d'autres données d'humidité du sol par satellite telles que SMAP, AMSR ou encore ASCAT. En effet, plus il y aura d'observations dans le schéma d'assimilation, plus il sera efficace.
- Pour le filtre particulaire, il serait intéressant de faire des perturbations plus progressives en fonction des gammes de pluie ou encore d'y ajouter de la cohérence spatiale des erreurs de précipitations.
- Une expérience réalisable serait d'assimiler les précipitations en amont avec l'API, puis de les utiliser en tant que forçage dans SURFEX.

### Estimation du rendement

- Nous avons vu précédemment le potentiel des cartes d'humidité à estimer les variations de rendement. Cependant, le calendrier des cultures étant basé sur la saison des pluies, et étant donné le caractère photopériodique des cultures de mil, pouvoir mieux définir ce calendrier permettrait d'affiner les estimations.
- Le potentiel prédictif serait à évaluer (dans une optique d'améliorer les alertes précoces).
- L'application de la méthode est aussi envisageable sur d'autres pays de la bande sahélienne. Cependant, une calibration des périodes en fonction des types de cultures ainsi que du régime de pluie est à envisager.
- Une étude multivariée combinant LST, NDVI et humidité permettrait de rendre plus robuste les relations.

Un premier essai, basé sur les anomalies de température de surface (LST MODIS) sur les zones de cultures a été réalisé. La Figure 5.21 présente la relation entre humidité du sol, température de surface et rendements de mil, les premiers résultats semblent très encourageants.

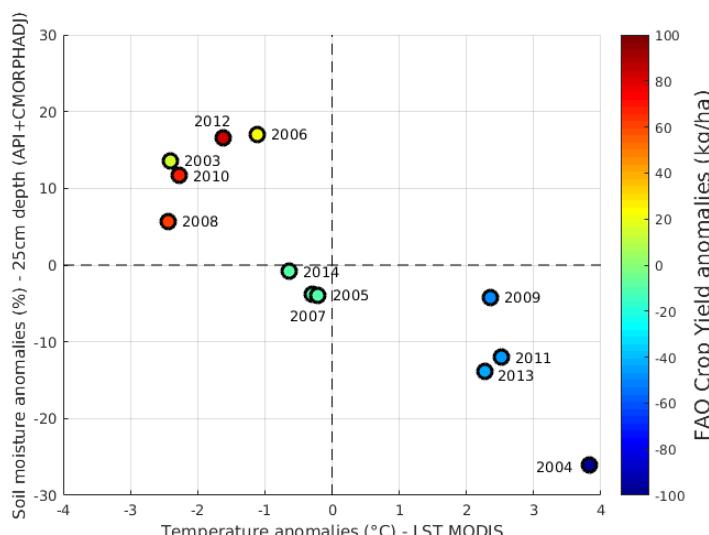


FIGURE 5.21 – Relation couplée humidité du sol et anomalie LST (Modis TERRA+AQUA) sur les rendements de mil à l'échelle du Niger.

- Il serait aussi intéressant d'étudier le caractère linéaire vs. non-linéaire de la relation humidité du sol vs. rendement

### TAMSAT

- Dans le cas de l'assimilation de TAMSAT, il serait intéressant d'étudier plus en profondeur les descentes d'échelle et les désagrégations (en particulier l'interpolation des coefficients).
- Il serait aussi intéressant de comparer le produit d'humidité du sol haute résolution avec d'autres produits (DISPATCH).
- Enfin, afin d'évaluer les différences de distribution spatiale de TAMSAT avant et après assimilation, il serait intéressant de le comparer avec des radars sol pour voir l'apport de l'assimilation de SMOS à la distribution spatiale.



# Bibliographie

- [ANF, 2014] (2014). Agence nationale des fréquences. Technical report. Contribution au groupe d'action mixte GAM4-5-6-7 de l'UIT sur la protection de la radioastronomie dans la bande 1400-1427 MHz.
- [Albergel et al., 2008] Albergel, C., Rüdiger, C., Pellarin, T., Calvet, J.-C., Fritz, N., Froissard, F., Suquia, D., Petitpa, A., Piguet, B., and Martin, E. (2008). From near-surface to root-zone soil moisture using an exponential filter : an assessment of the method based on in-situ observations and model simulations. *Hydrology and Earth System Sciences Discussions*, 12 :1323–1337.
- [Ali and Lebel, 2009] Ali, A. and Lebel, T. (2009). The sahelian standardized rainfall index revisited. *International Journal of Climatology*, 29(12) :1705–1714.
- [Anderson et al., 2013] Anderson, M. C., Hain, C., Otkin, J., Zhan, X., Mo, K., Svoboda, M., Wardlow, B., and Pimstein, A. (2013). An intercomparison of drought indicators based on thermal remote sensing and nldas-2 simulations with us drought monitor classifications. *Journal of Hydrometeorology*, 14(4) :1035–1056.
- [Barros et al., 2014] Barros, V., Field, C., Dokke, D., Mastrandrea, M., Mach, K., Bilir, T. E., Chatterjee, M., Ebi, K., Estrada, Y., Genova, R., et al. (2014). Climate change 2014 : impacts, adaptation, and vulnerability-part b : regional aspects-contribution of working group ii to the fifth assessment report of the intergovernmental panel on climate change.
- [Bennartz and Petty, 2001] Bennartz, R. and Petty, G. W. (2001). The sensitivity of microwave remote sensing observations of precipitation to ice particle size distributions. *Journal of Applied Meteorology*, 40(3) :345–364.
- [Beven and Germann, 2013] Beven, K. and Germann, P. (2013). Macropores and water flow in soils revisited. *Water Resources Research*, 49(6) :3071–3092.
- [Black et al., 2016] Black, E., Tarnavsky, E., Maidment, R., Greatrex, H., Mookerjee, A., Quaife, T., and Brown, M. (2016). The use of remotely sensed rainfall for managing drought risk : a case study of weather index insurance in zambia. *Remote Sensing*, 8(4) :342.
- [Blackadar, 1976] Blackadar, A. K. (1976). Modeling nocturnal boundary-layer. *Bulletin of the American Meteorological Society*, 57 :631–631.
- [Blayo et al., 2014] Blayo, E., Bocquet, M., Cosme, E., and Cugliandolo, L. F. (2014). Advanced data assimilation for geosciences.
- [Boé and Terray, 2014] Boé, J. and Terray, L. (2014). Land-sea contrast, soil-atmosphere and cloud-temperature interactions : interplays and roles in future summer european climate change. *Climate dynamics*, 42(3-4) :683–699.
- [Bolton and Friedl, 2013] Bolton, D. K. and Friedl, M. A. (2013). Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics. *Agricultural and Forest Meteorology*, 173 :74–84.
- [Brocca et al., 2014] Brocca, L., Ciabatta, L., Massari, C., Moramarco, T., Hahn, S., Hosenauer, S., Kidd, R., Dorigo, W., Wagner, W., and Levizzani, V. (2014). Soil as a natural rain

- gauge : Estimating global rainfall from satellite soil moisture data. *Journal of Geophysical Research : Atmospheres*, 119(9) :5128–5141.
- [Brocca et al., 2010] Brocca, L., Melone, F., Moramarco, T., Wagner, W., Naeimi, V., Bartalis, Z., and Hasenauer, S. (2010). Improving runoff prediction through the assimilation of the ascat soil moisture product. *Hydrology and Earth System Sciences*, 14(10) :1881.
- [Budyko, 1956] Budyko, M. (1956). Heat balance of the earth's. surface. *Gidrometeoizdat*.
- [Cappelaere et al., 2009] Cappelaere, B., Descroix, L., Lebel, T., Boulain, N., Ramier, D., Laurent, J., Favreau, G., Boubkraoui, S., Boucher, M., Moussa, I., Chaffard, V., Hiernaux, P., Issoufou, H., Le Breton, E., Mamadou, I., Nazoumou, Y., Oi, M., Ottle, C., and Quattin, G. (2009). The amma-catch experiment in the cultivated sahelian area of south-west niger - investigating water cycle response to a fluctuating climate and changing environment. *Journal of Hydrology*.
- [Ceballos et al., 2005] Ceballos, A., Scipal, K., Wagner, W., and Martínez-Fernández, J. (2005). Validation of ers scatterometer-derived soil moisture data in the central part of the duero basin, spain. *Hydrological processes*, 19(8) :1549–1566.
- [Champeaux et al., 2005] Champeaux, J., Masson, V., and Chauvin, F. (2005). Ecoclimap : a global database of land surface parameters at 1 km resolution. *Meteorological Applications*, 12(1) :29–32.
- [Clapp and Hornberger, 1978] Clapp, R. B. and Hornberger, G. M. (1978). Empirical equations for some soil hydraulic properties. *Water resources research*, 14(4) :601–604.
- [Crow et al., 2011] Crow, W., van Den Berg, M., Huffman, G., and Pellarin, T. (2011). Correcting rainfall using satellite-based surface soil moisture retrievals : The soil moisture analysis rainfall tool (smart). *Water Resources Research*, 47(8).
- [Crow and Wood, 2003] Crow, W. T. and Wood, E. F. (2003). The assimilation of remotely sensed soil brightness temperature imagery into a land surface model using ensemble kalman filtering : A case study based on estar measurements during sgp97. *Advances in Water Resources*, 26(2) :137–149.
- [Crutzen, 2002] Crutzen, P. J. (2002). Geology of mankind. *Nature*, 415(6867) :23–23.
- [Davidson, 1969] Davidson, R. (1969). Effects of soil nutrients and moisture on root/shoot ratios in lolium perenne l. and trifolium repens l. *Annals of Botany*, 33(3) :571–577.
- [Defrance et al., 2017] Defrance, D., Ramstein, G., Charbit, S., Vrac, M., Famien, A. M., Sultan, B., Swingedouw, D., Dumas, C., Gemenne, F., Alvarez-Solas, J., et al. (2017). Consequences of rapid ice sheet melting on the sahelian population vulnerability. *Proceedings of the National Academy of Sciences*, page 201619358.
- [Descroix et al., 2012] Descroix, L., Laurent, J.-P., Vauclin, M., Amogu, O., Boubkraoui, S., Ibrahim, B., Galle, S., Cappelaere, B., Bousquet, S., Mamadou, I., et al. (2012). Experimental evidence of deep infiltration under sandy flats and gullies in the sahel. *Journal of Hydrology*, 424 :1–15.
- [Dorigo et al., 2011] Dorigo, W., Wagner, W., Hohensinn, R., Hahn, S., Paulik, C., Xaver, A., Gruber, A., Drush, M., Mecklenburg, S., van Oevelen, P., Robock, A., and Jackson, T. (2011). The International Soil Moisture Network : a data hosting facility for global in situ soil moisture measurments. *Hydrology and Earth System Sciences*.
- [Draper et al., 2012] Draper, C., Reichle, R., De Lannoy, G., and Liu, Q. (2012). Assimilation of passive and active microwave soil moisture retrievals. *Geophysical Research Letters*, 39(4).
- [Eldin, 1990] Eldin, O. (1990). Croissance et développement du mil (pennisetum typhoides) sous deux conditions de fumure minérale : rapport de stage.

- [Entekhabi et al., 2010a] Entekhabi, D., Njoku, E. G., O'Neill, P. E., Kellogg, K. H., Crow, W. T., Edelstein, W. N., Entin, J. K., Goodman, S. D., Jackson, T. J., Johnson, J., et al. (2010a). The soil moisture active passive (smap) mission. *Proceedings of the IEEE*, 98(5) :704–716.
- [Entekhabi et al., 2010b] Entekhabi, D., Reichle, R. H., Koster, R. D., and Crow, W. T. (2010b). Performance metrics for soil moisture retrievals and application requirements. *Journal of Hydrometeorology*, 11(3) :832–840.
- [FAO, 1988] FAO, F. (1988). Unesco soil map of the world, revised legend. *World Resources Report*, 60 :138.
- [Fernandez-Moran et al., 2017] Fernandez-Moran, R., Al-Yaari, A., Mialon, A., Mahmoodi, A., Al Bitar, A., De Lannoy, G., Rodriguez-Fernandez, N., Lopez-Baeza, E., Kerr, Y., and Wi-gneron, J.-P. (2017). Smos-ic : An alternative smos soil moisture and vegetation optical depth product. *Remote Sensing*, 9(5) :457.
- [Fischer et al., 2005] Fischer, G., Shah, M., Tubiello, F. N., and Van Velhuizen, H. (2005). Socio-economic and climate change impacts on agriculture : an integrated assessment, 1990–2080. *Philosophical Transactions of the Royal Society of London B : Biological Sciences*, 360(1463) :2067–2083.
- [Funk and Budde, 2009] Funk, C. and Budde, M. E. (2009). Phenologically-tuned modis ndvi-based production anomaly estimates for zimbabwe. *Remote Sensing of Environment*, 113(1) :115–125.
- [Gadelle, 2001] Gadelle, F. (2001). L'avenir de l'irrigation en afrique de l'ouest.
- [Galle et al., 2004] Galle, S., Laurent, J.-P., and Séguis, L. (2004). Monitoring water fluxes in soils within the donga river basin, bénin, west-africa. *EGU. 1st General Assembly, Nice, Geophysical Research Abstracts*.
- [Galle et al., 2007] Galle, S., Séguis, L., Gosset, M., Peugeot, C., Le Lay, M., Robain, H., Se-ghieri, J., Wubda, M. S. L., and M., B. (2007). Singularity and generality of hydrological functioning of three catena with different vegetation covers. *J.-L. Redelsberger (Editor), 2nd AMMA Int. Conf. AMMA, Karlsruhe (Germany)*.
- [Gaspar et al., 1990] Gaspar, P., André, J.-C., and Lefevre, J.-M. (1990). The determination of the latent and sensible heat fluxes at the sea surface viewed as an inverse problem. *Journal of Geophysical Research : Oceans*, 95(C9) :16169–16178.
- [Gelaro et al., 2017] Gelaro, R., McCarty, W., Suárez, M. J., Todling, R., Molod, A., Takacs, L., Randles, C. A., Darmenov, A., Bosilovich, M. G., Reichle, R., et al. (2017). The modern-era retrospective analysis for research and applications, version 2 (merra-2). *Journal of Climate*, 30(14) :5419–5454.
- [Gleick, 1993] Gleick, P. H. (1993). *Water in crisis : a guide to the world's fresh water resources*.
- [Gosset et al., 2013] Gosset, M., Viarre, J., Quantin, G., and Alcoba, M. (2013). Evaluation of several rainfall products used for hydrological applications over west africa using two high-resolution gauge networks. *Quarterly Journal of the Royal Meteorological Society*, 139(673) :923–940.
- [Guan et al., 2016] Guan, K., Berry, J. A., Zhang, Y., Joiner, J., Guanter, L., Badgley, G., and Lobell, D. B. (2016). Improving the monitoring of crop productivity using spaceborne solar-induced fluorescence. *Global change biology*, 22(2) :716–726.
- [Guan et al., 2015] Guan, K., Sultan, B., Biasutti, M., Baron, C., and Lobell, D. B. (2015). What aspects of future rainfall changes matter for crop yields in west africa ? *Geophysical Research Letters*, 42(19) :8001–8010.

- [Guan et al., 2014] Guan, K., Wood, E. F., Medvigy, D., Kimball, J., Pan, M., Caylor, K. K., Sheffield, J., Xu, X., and Jones, M. O. (2014). Terrestrial hydrological controls on land surface phenology of african savannas and woodlands. *Journal of Geophysical Research : Biogeosciences*, 119(8) :1652–1669.
- [Ganter et al., 2014] Guanter, L., Zhang, Y., Jung, M., Joiner, J., Voigt, M., Berry, J. A., Frankenberg, C., Huete, A. R., Zarco-Tejada, P., Lee, J.-E., et al. (2014). Global and time-resolved monitoring of crop photosynthesis with chlorophyll fluorescence. *Proceedings of the National Academy of Sciences*, 111(14) :E1327–E1333.
- [Hillel, 1987] Hillel, D. (1987). Unstable flow in layered soils : a review. *Hydrological Processes*, 1(2) :143–147.
- [Hillel, 1998] Hillel, D. (1998). *Environmental Soil Physics*.
- [Hoffman et al., 2015] Hoffman, L. A., Etienne, X. L., Irwin, S. H., Colino, E. V., and Toasa, J. I. (2015). Forecast performance of wasde price projections for u.s. corn. *Agricultural Economics*, 46(S1) :157–171.
- [Houser et al., 2012] Houser, P. R., De Lannoy, G., and Walker, J. P. (2012). *Hydrological Data Assimilation*. InTech.
- [Houser et al., 1998] Houser, P. R., Shuttleworth, W. J., Famiglietti, J. S., Gupta, H. V., Syed, K. H., and Goodrich, D. C. (1998). Integration of soil moisture remote sensing and hydrologic modeling using data assimilation. *Water Resources Research*, 34(12) :3405–3420.
- [Huffman et al., 2010] Huffman, G. J., Adler, R. F., Bolvin, D. T., and Nelkin, E. J. (2010). The trmm multi-satellite precipitation analysis (tmpa). In *Satellite rainfall applications for surface hydrology*, pages 3–22. Springer.
- [Huffman et al., 2001] Huffman, G. J., Adler, R. F., Morrissey, M. M., Bolvin, D. T., Curtis, S., Joyce, R., McGavock, B., and Susskind, J. (2001). Global precipitation at one-degree daily resolution from multisatellite observations. *Journal of Hydrometeorology*, 2(1) :36–50.
- [Ickowicz et al., 2012] Ickowicz, A., Ancey, V., Corniaux, C., Duteurtre, G., Poccard-Chappuis, R., Touré, I., Vall, E., and Wane, A. (2012). Crop–livestock production systems in the sahel—increasing resilience for adaptation to climate change and preserving food security. *Building resilience for adaptation to climate change in the agriculture sector*, 23 :261.
- [Ines et al., 2013] Ines, A. V., Das, N. N., Hansen, J. W., and Njoku, E. G. (2013). Assimilation of remotely sensed soil moisture and vegetation with a crop simulation model for maize yield prediction. *Remote Sensing of Environment*, 138 :149–164.
- [JAICAF, 2009] JAICAF (2009). Les céréales au niger.
- [Jaynes and Hunsaker, 1989] Jaynes, D. and Hunsaker, D. (1989). Spatial and temporal variability of water content and infiltration on a flood irrigated field. *Transactions of the ASAE*, 32(4) :1229–1238.
- [Joyce et al., 2004] Joyce, R. J., Janowiak, J. E., Arkin, P. A., and Xie, P. (2004). Cmorph : A method that produces global precipitation estimates from passive microwave and infrared data at high spatial and temporal resolution. *Journal of Hydrometeorology*, 5(3) :487–503.
- [Kachanoski and Jong, 1988] Kachanoski, R. and Jong, E. (1988). Scale dependence and the temporal persistence of spatial patterns of soil water storage. *Water Resources Research*, 24(1) :85–91.
- [Kerr et al., 2016] Kerr, Y. H., Al-Yaari, A., Rodriguez-Fernandez, N., Parrens, M., Molero, B., Leroux, D., Bircher, S., Mahmoodi, A., Mialon, A., Richaume, P., et al. (2016). Overview of smos performance in terms of global soil moisture monitoring after six years in operation. *Remote Sensing of Environment*, 180 :40–63.

- [Kerr et al., 2011] Kerr, Y. H., Waldteufel, P., Richaume, P., Wigneron, J.-P., Ferrazzoli, P., and Gurney, R. (2011). SMOS level 2 processor for soil moisture - Algorithm Theoretical Based Document (ATBD) . Technical Report SO-TN-ESL-SM-GS-0001, Issue 3.e, CBSA. 121 p.
- [Kerr et al., 2012] Kerr, Y. H., Waldteufel, P., Richaume, P., Wigneron, J. P., Ferrazzoli, P., Mahmoodi, A., Al Bitar, A., Cabot, F., Gruhier, C., Juglea, S. E., Leroux, D., Mialon, A., and Delwart, S. (2012). The SMOS Soil Moisture Retrieval Algorithm. *Geoscience and Remote Sensing, IEEE Transactions on*, 50(5) :1384 –1403.
- [Kerr et al., 2001] Kerr, Y. H., Waldteufel, P., Wigneron, J.-P., Martinuzzi, J., Font, J., and Berger, M. (2001). Soil moisture retrieval from space : The soil moisture and ocean salinity (smos) mission. *IEEE transactions on Geoscience and remote sensing*, 39(8) :1729–1735.
- [Kidd and Levizzani, 2011] Kidd, C. and Levizzani, V. (2011). Status of satellite precipitation retrievals. *Hydrology and Earth System Sciences*, 15(4) :1109–1116.
- [Koster et al., 2004] Koster, R. D., Dirmeyer, P. A., Guo, Z., Bonan, G., Chan, E., Cox, P., Gordon, C. T., Kanae, S., Kowalczyk, E., Lawrence, D., Liu, P., Lu, C.-H., Malyshev, S., McAvaney, B., Mitchell, K., Mocko, D., Oki, T., Oleson, K., Pitman, A., Sud, Y. C., Taylor, C. M., Verseghy, D., Vasic, R., Xue, Y., and Yamada, T. (2004). Regions of Strong Coupling Between Soil Moisture and Precipitation. *Science*, 305(5687) :1138–1140.
- [Kuchenbuch et al., 1986] Kuchenbuch, R., Claassen, N., and Jungk, A. (1986). Potassium availability in relation to soil moisture. *Plant and Soil*, 95(2) :233–243.
- [Kumar et al., 2014] Kumar, S. V., Peters-Lidard, C. D., Mocko, D., Reichle, R., Liu, Y., Arsenault, K. R., Xia, Y., Ek, M., Riggs, G., Livneh, B., et al. (2014). Assimilation of remotely sensed soil moisture and snow depth retrievals for drought estimation. *Journal of Hydrometeorology*, 15(6) :2446–2469.
- [Kummerow et al., 1998] Kummerow, C., Barnes, W., Kozu, T., Shiue, J., and Simpson, J. (1998). The tropical rainfall measuring mission (trmm) sensor package. *Journal of atmospheric and oceanic technology*, 15(3) :809–817.
- [Lal, 2008] Lal, R. (2008). Carbon sequestration. *Philosophical Transactions of the Royal Society of London B : Biological Sciences*, 363(1492) :815–830.
- [Le Moigne, 2009] Le Moigne, P. (2009). Surfex scientific documentation. note de centre du groupe de meteorologie à moyenne echelle. Technical report.
- [Lebel et al., 2009] Lebel, T., Cappelaere, B., Galle, S., Hanan, N., Kerfoot, L., Levis, S., Vieux, B., Descroix, L., Gosset, M., Mougin, E., Peugeot, C., and Seguis, L. (2009). AMMA-CATCH studies in the sahelian region of west-africa : An overview. 375(1) :3–13.
- [Leroux, 2016] Leroux, D. J. (2016). Assimilation of smos soil moisture into a distributed hydrological model and impacts on the water cycle variables over the ouémé catchment in benin. *Hydrology and Earth System Sciences*, 20(7) :2827.
- [Leroux et al., 2016] Leroux, L., Baron, C., Zoungrana, B., Traoré, S. B., Seen, D. L., and Bégué, A. (2016). Crop monitoring using vegetation and thermal indices for yield estimates : Case study of a rainfed cereal in semi-arid west africa. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(1) :347–362.
- [Lesk et al., 2016] Lesk, C., Rowhani, P., and Ramankutty, N. (2016). Influence of extreme weather disasters on global crop production. *Nature*, 529(7584) :84–87.
- [Liu et al., 2011] Liu, Y. Y., de Jeu, R. A., McCabe, M. F., Evans, J. P., and van Dijk, A. I. (2011). Global long-term passive microwave satellite-based retrievals of vegetation optical depth. *Geophysical Research Letters*, 38(18).

- [Liu et al., 2009] Liu, Y. Y., van Dijk, A. I., de Jeu, R. A., and Holmes, T. R. (2009). An analysis of spatiotemporal variations of soil and vegetation moisture from a 29-year satellite-derived data set over mainland australia. *Water Resources Research*, 45(7).
- [Lobell and Field, 2007] Lobell, D. B. and Field, C. B. (2007). Global scale climate–crop yield relationships and the impacts of recent warming. *Environmental research letters*, 2(1) :014002.
- [Loew et al., 2017] Loew, A., Bell, W., Brocca, L., Bulgin, C. E., Burdanowitz, J., Calbet, X., Donner, R. V., Ghent, D., Gruber, A., Kaminski, T., et al. (2017). Validation practices for satellite based earth observation data across communities. *Reviews of Geophysics*.
- [Louvet et al., 2015] Louvet, S., Pellarin, T., al Bitar, A., Cappelaere, B., Galle, S., Grippa, M., Gruhier, C., Kerr, Y., Lebel, T., Mialon, A., Mougin, E., Quantin, G., Richaume, P., and de Rosnay, P. (2015). Smos soil moisture product evaluation over west-africa from local to regional scale. *Remote Sensing of Environment*, 156 :383–394.
- [Ly et al., 2010] Ly, C., Fall, A., and Okike, I. (2010). The livestock sector in need of regional strategies. *Livestock in a changing landscape : Experiences and regional perspectives*, page 27.
- [Mahalakshmi et al., 1987] Mahalakshmi, V., Bidinger, F., and Raju, D. (1987). Effect of timing of water deficit on pearl millet (*pennisetum americanum*). *Field Crops Research*, 15(3-4) :327–339.
- [Mahfouf et al., 2009] Mahfouf, J.-F., Bergaoui, K., Draper, C., Bouyssel, F., Taillefer, F., and Taseva, L. (2009). A comparison of two off-line soil analysis schemes for assimilation of screen level observations. *Journal of Geophysical Research : Atmospheres*, 114(D8) :D08105.
- [Maidment et al., 2017] Maidment, R., Black, E., and Young, M. (2017). Tamsat daily rainfall estimates (version 3.0).
- [Manabe, 1969] Manabe, S. (1969). Climate and the ocean circulation1. *Monthly Weather Review*, 97(11) :739–774.
- [Margulis et al., 2002] Margulis, S. A., McLaughlin, D., Entekhabi, D., and Dunne, S. (2002). Land data assimilation and estimation of soil moisture using measurements from the southern great plains 1997 field experiment. *Water resources research*, 38(12).
- [Marsaglia and Tsang, 2000] Marsaglia, G. and Tsang, W. W. (2000). A simple method for generating gamma variables. *ACM Transactions on Mathematical Software (TOMS)*, 26(3) :363–372.
- [Marteau et al., 2011] Marteau, R., Sultan, B., Moron, V., Alhassane, A., Baron, C., and Traoré, S. B. (2011). The onset of the rainy season and farmers' sowing strategy for pearl millet cultivation in southwest niger. *Agricultural and forest meteorology*, 151(10) :1356–1369.
- [Martin et al., 2007] Martin, E., Le Moigne, P., Masson, V., Kullmann, C. L., Lacarrère, P., Lebeaupin, C., Mahfouf, J.-F., Malardel, S., Mallet, I., and et al., M. P. (2007). Le code de surface externalise surfex de meteo- france.
- [Maselli et al., 1992] Maselli, F., Conese, C., Petkov, L., and Gilabert, M.-A. (1992). Use of noaa-avhrr ndvi data for environmental monitoring and crop forecasting in the sahel. preliminary results. *International Journal of Remote Sensing*, 13(14) :2743–2749.
- [Masson, 2000] Masson, V. (2000). A physically-based scheme for the urban energy budget in atmospheric models. *Boundary-layer meteorology*, 94(3) :357–397.
- [McColl et al., 2017] McColl, K. A., Alemohammad, S. H., Akbar, R., Konings, A. G., Yueh, S., and Entekhabi, D. (2017). The global distribution and dynamics of surface soil moisture. *Nature Geoscience*, 10(2) :100–104.
- [McNally et al., 2015] McNally, A., Husak, G. J., Brown, M., Carroll, M., Funk, C., Yatheendradas, S., Arsenault, K., Peters-Lidard, C., and Verdin, J. P. (2015). Calculating crop water

- requirement satisfaction in the west africa sahel with remotely sensed soil moisture. *Journal of Hydrometeorology*, 16(1) :295–305.
- [Meehl et al., ] Meehl, G. A., Meehl, G. A., Stocker, T. F., Collins, W. D., Friedlingstein, P., Gaye, A. T., Gregory, J. M., Kitoh, A., Knutti, R., Murphy, J. M., Noda, A., Raper, S. C. B., Watterson, I. G., Weaver, A. J., Zhao, Z. C., and IPCC, . Global climate projections. In *Climate Change 2007 : The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press.
- [Mkhabela et al., 2011] Mkhabela, M., Bullock, P., Raj, S., Wang, S., and Yang, Y. (2011). Crop yield forecasting on the canadian prairies using modis ndvi data. *Agricultural and Forest Meteorology*, 151(3) :385–393.
- [Müller et al., 2010] Müller, C., Bondeau, A., Popp, A., Waha, K., and Fader, M. (2010). Climate change impacts on agricultural yields.
- [Noilhan and Mahfouf, 1996] Noilhan, J. and Mahfouf, J.-F. (1996). The isba land surface parameterisation scheme. *Global and planetary Change*, 13(1-4) :145–159.
- [Orchard and Cook, 1983] Orchard, V. A. and Cook, F. (1983). Relationship between soil respiration and soil moisture. *Soil Biology and Biochemistry*, 15(4) :447–453.
- [Ouendeba and Siaka Sogoba, 2004] Ouendeba, B. and Siaka Sogoba, B. (2004). Le mil [penisetum glaucum (l.) r. br.] au niger : généralités et résultats de la sélection in : Ressources génétiques des mils en afrique de l'ouest : Diversité, conservation et valorisation.
- [Panthou et al., 2014] Panthou, G., Vischel, T., and Lebel, T. (2014). Recent trends in the regime of extreme rainfall in the central sahel. *International Journal of Climatology*, 34(15) :3998–4006.
- [Parlange et al., 1989] Parlange, M., Steenhuijsen, T., Timlin, D., Stagnitti, F., and Bryant, R. (1989). Subsurface flow above a fragipan horizon. *Soil Science*, 148(2) :77–86.
- [Parry et al., 2005] Parry, M., Rosenzweig, C., and Livermore, M. (2005). Climate change, global food supply and risk of hunger. *Philosophical Transactions of the Royal Society B : Biological Sciences*, 360(1463) :2125–2138.
- [Pastor and Post, 1986] Pastor, J. and Post, W. (1986). Influence of climate, soil moisture, and succession on forest carbon and nitrogen cycles. *Biogeochemistry*, 2(1) :3–27.
- [Pauwels et al., 2001] Pauwels, V. R., Hoeben, R., Verhoest, N. E., and De Troch, F. P. (2001). The importance of the spatial patterns of remotely sensed soil moisture in the improvement of discharge predictions for small-scale basins through data assimilation. *Journal of Hydrology*, 251(1) :88–102.
- [Pellarin et al., 2009] Pellarin, T., Laurent, J. P., Cappelaere, B., Decharme, B., Descroix, L., and Ramier, D. (2009). Hydrological modelling and associated microwave emission of a semi-arid region in south-western niger. 375(1) :262–272.
- [Pellarin et al., 2013] Pellarin, T., Louvet, S., Gruhier, C., Quantin, G., and Legout, C. (2013). A simple and effective method for correcting soil moisture and precipitation estimates using amsr-e measurements. *Remote sensing of environment*, 136 :28–36.
- [Peng et al., 2017] Peng, J., Loew, A., Merlin, O., and Verhoest, N. E. (2017). A review of spatial downscaling of satellite remotely sensed soil moisture. *Reviews of Geophysics*.
- [Pitman, 2003] Pitman, A. (2003). The evolution of, and revolution in, land surface schemes designed for climate models. *International Journal of Climatology*, 23(5) :479–510.
- [Ramarohetra et al., 2013] Ramarohetra, J., Sultan, B., Baron, C., Gaiser, T., and Gosset, M. (2013). How satellite rainfall estimate errors may impact rainfed cereal yield simulation in west africa. *Agricultural and forest meteorology*, 180 :118–131.

- [Rebecca et al., 2015] Rebecca, S., Anne, V., and Pam, F. (2015). Surveiller l'humidité du sol pour améliorer les décisions d'irrigation.
- [Redelsperger et al., 2006] Redelsperger, J.-L., Thorncroft, C. D., Diedhiou, A., Lebel, T., Parker, D. J., and Polcher, J. (2006). African monsoon multidisciplinary analysis : An international research project and field campaign. *Bulletin of the American Meteorological Society*, 87(12) :1739–1746.
- [Reichle and Koster, 2003] Reichle, R. H. and Koster, R. D. (2003). Assessing the impact of horizontal error correlations in background fields on soil moisture estimation. *Journal of Hydrometeorology*, 4(6) :1229–1242.
- [Reichle and Koster, 2004] Reichle, R. H. and Koster, R. D. (2004). Bias reduction in short records of satellite soil moisture. *Geophysical Research Letters*, 31(19).
- [Reichle et al., 2002] Reichle, R. H., McLaughlin, D. B., and Entekhabi, D. (2002). Hydrologic data assimilation with the ensemble kalman filter. *Monthly Weather Review*, 130(1) :103–114.
- [Richards, 1931] Richards, L. A. (1931). Capillary Conduction of Liquids Through Porous Mediums. *Physics*, 1 :318–333.
- [Rockström, 1999] Rockström, J. (1999). On-farm green water estimates as a tool for increased food production in water scarce regions. *Physics and Chemistry of the Earth, Part B : Hydrology, Oceans and Atmosphere*, 24(4) :375–383.
- [Rockström and De Rouw, 1997] Rockström, J. and De Rouw, A. (1997). Water, nutrients and slope position in on-farm pearl millet cultivation in the sahel. *Plant and Soil*, 195(2) :311–327.
- [Rockström et al., 2009] Rockström, J., Steffen, W., Noone, K., Persson, Å., Chapin, F. S., Lambin, E. F., Lenton, T. M., Scheffer, M., Folke, C., Schellnhuber, H. J., et al. (2009). A safe operating space for humanity. *nature*, 461(7263) :472–475.
- [Rodriguez-Fernandez et al., 2014] Rodriguez-Fernandez, N., Richaume, P., Aires, F., Prigent, C., Kerr, Y., Kolassa, J., Jimenez, C., Cabot, F., and Mahmoodi, A. (2014). Soil moisture retrieval from smos observations using neural networks. In *Geoscience and Remote Sensing Symposium (IGARSS), 2014 IEEE International*, pages 2431–2434. IEEE.
- [Román-Cascón et al., 2017] Román-Cascón, C., Pellarin, T., Gibon, F., Brocca, L., Cosme, E., Crow, W., Fernández-Prieto, D., Kerr, Y. H., and Massari, C. (2017). Correcting satellite-based precipitation products through smos soil moisture data assimilation in two land-surface models of different complexity : Api and surfex. *Remote Sensing of Environment*, 200 :295–310.
- [Rosenzweig and Parry, 1994] Rosenzweig, C. and Parry, M. L. (1994). Potential impact of climate change on world food supply. *Nature*, 367(6459) :133–138.
- [Roudier et al., 2011] Roudier, P., Sultan, B., Quirion, P., and Berg, A. (2011). The impact of future climate change on west african crop yields : What does the recent literature say ? *Global Environmental Change*, 21(3) :1073–1083.
- [Salgado and Le Moigne, 2010] Salgado, R. and Le Moigne, P. (2010). Coupling of the flake model to the surfex externalized surface model.
- [Schneider and Childers, 1941] Schneider, G. W. and Childers, N. (1941). Influence of soil moisture on photosynthesis, respiration, and transpiration of apple leaves. *Plant physiology*, 16(3) :565.
- [Sellers et al., 1992] Sellers, P., Berry, J., Collatz, G., Field, C., and Hall, F. (1992). Canopy reflectance, photosynthesis, and transpiration. iii. a reanalysis using improved leaf models and a new canopy integration scheme. *Remote sensing of environment*, 42(3) :187–216.

- [Seneviratne et al., 2010] Seneviratne, S. I., Corti, T., Davin, E. L., Hirschi, M., Jaeger, E. B., Lehner, I., Orlowsky, B., and Teuling, A. J. (2010). Investigating soil moisture–climate interactions in a changing climate : A review. *Earth-Science Reviews*, 99(3–4) :125–161.
- [Seneviratne et al., 2006] Seneviratne, S. I., Koster, R. D., Guo, Z., Dirmeyer, P. A., Kowalczyk, E., Lawrence, D., Liu, P., Mocko, D., Lu, C.-H., Oleson, K. W., et al. (2006). Soil moisture memory in agcm simulations : analysis of global land–atmosphere coupling experiment (glace) data. *Journal of Hydrometeorology*, 7(5) :1090–1112.
- [Seuffert et al., 2003] Seuffert, G., Wilker, H., Viterbo, P., Mahfouf, J.-F., Drusch, M., and Calvet, J.-C. (2003). Soil moisture analysis combining screen-level parameters and microwave brightness temperature : A test with field data. *Geophysical research letters*, 30(10).
- [Sharma et al., 1980] Sharma, M., Gander, G., and Hunt, C. (1980). Spatial variability of infiltration in a watershed. *Journal of Hydrology*, 45(1-2) :101–122.
- [Sisson and Wierenga, 1981] Sisson, J. B. and Wierenga, P. (1981). Spatial variability of steady-state infiltration rates as a stochastic process. *Soil Science Society of America Journal*, 45(4) :699–704.
- [Soltner, 1989] Soltner, D. (1989). *Les bases de la production végétale : phytotechnie générale : le sol, le climat, la plante*. Number vol. 1 in Les bases de la production végétale : phytotechnie générale : le sol, le climat, la plante. Sciences et techniques agricoles.
- [Sorooshian et al., 2000] Sorooshian, S., Hsu, K.-L., Gao, X., Gupta, H. V., Imam, B., and Braithwaite, D. (2000). Evaluation of persiann system satellite–based estimates of tropical rainfall. *Bulletin of the American Meteorological Society*, 81(9) :2035–2046.
- [Sparling et al., 1987] Sparling, G., Milne, J., and Vincent, K. (1987). Effect of soil moisture regime on the microbial contribution to olsen phosphorus values. *New Zealand Journal of Agricultural Research*, 30(1) :79–84.
- [Steffen et al., 2006] Steffen, W., Sanderson, R. A., Tyson, P. D., Jäger, J., Matson, P. A., Moore III, B., Oldfield, F., Richardson, K., Schellnhuber, H. J., Turner, B. L., et al. (2006). *Global change and the earth system : a planet under pressure*. Springer Science & Business Media.
- [Steiner et al., 2003] Steiner, M., Bell, T. L., Zhang, Y., and Wood, E. F. (2003). Comparison of two methods for estimating the sampling-related uncertainty of satellite rainfall averages based on a large radar dataset. *Journal of Climate*, 16(22) :3759–3778.
- [Sylla et al., 2010] Sylla, M., Gaye, A., Jenkins, G., Pal, J. S., and Giorgi, F. (2010). Consistency of projected drought over the sahel with changes in the monsoon circulation and extremes in a regional climate model projections. *Journal of Geophysical Research : Atmospheres*, 115(D16).
- [Trenberth et al., 2007] Trenberth, K. E., Smith, L., Qian, T., Dai, A., and Fasullo, J. (2007). Estimates of the global water budget and its annual cycle using observational and model data. *Journal of Hydrometeorology*, 8(4) :758–769.
- [Tucker, 1979] Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2) :127–150.
- [Vachaud et al., 1985] Vachaud, G., Passerat de Silans, A., Balabanis, P., and Vauclin, M. (1985). Temporal stability of spatially measured soil water probability density function. *Soil Science Society of America Journal*, 49(4) :822–828.
- [Vieira et al., 1981] Vieira, S. R., Nielsen, D., and Biggar, J. (1981). Spatial variability of field-measured infiltration rate. *Soil Science Society of America Journal*, 45(6) :1040–1048.
- [Wagner et al., 1999] Wagner, W., Lemoine, G., and Rott, H. (1999). A method for estimating soil moisture from ers scatterometer and soil data. *Remote sensing of environment*, 70(2) :191–207.

- [Walker and Houser, 2001] Walker, J. P. and Houser, P. R. (2001). A methodology for initializing soil moisture in a global climate model : Assimilation of near-surface soil moisture observations. *Journal of Geophysical Research : Atmospheres*, 106(D11) :11761–11774.
- [Wanders et al., 2014a] Wanders, N., Bierkens, M. F., de Jong, S. M., de Roo, A., and Karssenberg, D. (2014a). The benefits of using remotely sensed soil moisture in parameter identification of large-scale hydrological models. *Water resources research*, 50(8) :6874–6891.
- [Wanders et al., 2014b] Wanders, N., Karssenberg, D., Roo, A. d., De Jong, S., and Bierkens, M. (2014b). The suitability of remotely sensed soil moisture for improving operational flood forecasting. *Hydrology and Earth System Sciences*, 18(6) :2343–2357.
- [Whitcraft et al., 2015] Whitcraft, A. K., Becker-Reshef, I., and Justice, C. O. (2015). A framework for defining spatially explicit earth observation requirements for a global agricultural monitoring initiative (geoglam). *Remote Sensing*, 7(2) :1461–1481.
- [Wigneron et al., 2007] Wigneron, J.-P., Kerr, Y. H., Waldteufel, P., Saleh, K., Escorihuela, M.-J., Richaume, P., Ferrazzoli, P., de Rosnay, P., Gurney, R., Calvet, J.-C., Grant, J. P., Guglielmetti, M., Hornbuckle, B., Mätzler, C., Pellarin, T., and Schwank, M. (2007). L-band Microwave Emission of the Biosphere (L-MEB) Model : Description and calibration against experimental data sets over crop fields. *Rem. Sens. Environ.*, 107 :639–655.

# Annexe A

## Théorie de la modélisation de l'émission naturelle dans les micro-ondes

Les radiomètres passifs, comme dans le cas de SMOS, utilisent des fondamentaux de physique ondulatoire pour retrouver des paramètres physiques de cibles via télédétection (sans contact). Pour mieux comprendre les phénomènes physiques mis en jeu dans le cas de la radio-métrie, rappelons les grandes lignes théoriques de l'onde électromagnétique.

### A.1 Généralité sur l'onde électromagnétique

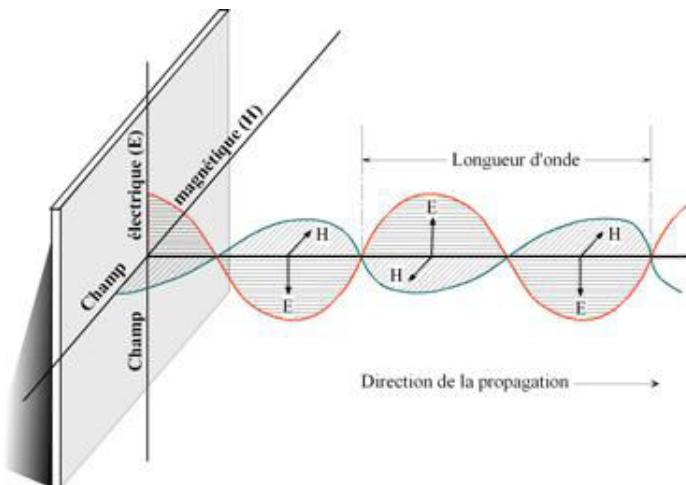


FIGURE A.1 – Représentation classique d'une onde électromagnétique. Source : [health.belgium.be](http://health.belgium.be)

L'onde électromagnétique est une représentation du phénomène de rayonnement électromagnétique. Ce phénomène physique représente un transfert d'énergie dans un milieu. Ce transfert d'énergie est caractérisé par une variation du champ magnétique et électrique dans l'espace et le temps.

Chaque onde est caractérisée par son déphasage entre champ électrique et magnétique (polarisation), sa fréquence, son amplitude et sa direction de propagation. Les propriétés d'une onde électromagnétique par rapport à son milieu de propagation sont régies par des lois : les équations de Maxwell. Dans le cas d'une propagation dans un milieu naturel tel que l'atmosphère, le sol ou encore la végétation, on considère le milieu sans charges, non-conducteur et non-magnétique.

Les équations de Maxwell adaptées à ces milieux deviennent alors :

$$\left\{ \begin{array}{lcl} \nabla \cdot \vec{E} & = & 0 \\ \nabla \cdot \vec{B} & = & 0 \\ \nabla \times \vec{E} + \frac{\delta \vec{B}}{\delta t} & = & 0 \\ \nabla \times \vec{B} - \frac{\mu_r \varepsilon_r}{c^2} \cdot \frac{\delta \vec{E}}{\delta t} & = & 0 \end{array} \right. \quad (\text{A.1})$$

Avec :

- $\vec{E}, \vec{B}$  : champ électrique et magnétique de l'onde
- $\varepsilon_r, \mu_r$  : permittivité électrique et magnétique relative au milieu
- $\varepsilon_0, \mu_0$  : permittivité électrique et magnétique relative au milieu
- $c$  : vitesse de la lumière

*Notons que les permittivités électriques et magnétiques du milieu sont calculées à partir de  $\varepsilon = \varepsilon_r \varepsilon_0$  et de  $\mu = \mu_r \mu_0$ . Elles représentent l'influence du milieu sur la propagation de ces champs électromagnétiques.*

À partir de ces 4 équations fondamentales sont déduites les équations d'ondes caractérisant la propagation de l'onde dans le milieu naturel, spatialement et temporellement :

$$\left\{ \begin{array}{lcl} \nabla^2 \cdot \vec{E} - \frac{\mu \varepsilon}{c^2} \frac{\delta^2 \vec{E}}{\delta t^2} & = & 0 \\ \nabla^2 \cdot \vec{B} - \frac{\mu \varepsilon}{c^2} \frac{\delta^2 \vec{B}}{\delta t^2} & = & 0 \end{array} \right. \quad (\text{A.2})$$

La résolution mathématique de ces équations permet de décrire la propagation de l'onde selon l'équation d'onde suivante (monochromatique et propagation selon l'axe  $\vec{z}$ ) :

$$\vec{E}_x(t, \vec{z}) = \vec{E}_0 \cos(\omega_c \cdot t - \vec{k} \cdot \vec{z} + \varphi) \quad (\text{A.3})$$

Avec :

- $\omega_c$  : pulsation temporelle de l'onde égale à  $2\pi f$  ou  $2\pi T^{-1}$
- $k$  : nombre d'onde, nombre de pulsation spatiale égale à  $2\pi \lambda^{-1}$
- $\varphi$  : phase à l'origine

Ainsi, avec les ÉQUATION (A.1) et (A.3), on retrouve la relation entre les pulsations spatiales et temporelles relatives aux permittivités :

$$\frac{\omega_c}{k} = \frac{1}{\sqrt{\varepsilon \mu}} \quad (\text{A.4})$$

On définit aussi la notion de vitesse de phase  $V_\varphi$  comme étant la vitesse de propagation de l'onde dans un milieu donné (ici selon l'axe  $\vec{z}$ ) :

$$V_\varphi = \frac{dz}{dt} = \frac{\omega_c}{k} \quad (\text{A.5})$$

Soit dans le cas du vide et à partir de ÉQUATION (A.4) et (A.5), on retrouve bien la vitesse de propagation égal à la vitesse de la lumière :

$$V_\varphi = \frac{\omega_{c0}}{k_0} = \frac{1}{\sqrt{\varepsilon_0 \mu_0}} = c \quad (\text{A.6})$$

Une notion très importante en télédétection, passive ou active, est la notion de polarisation. Considérons le cas d'une onde plane. Cette onde à la particularité de conserver ses champs  $\vec{E}$  et  $\vec{B}$  dans leurs plans respectifs, les plans de polarisations. Chaque champ,  $\vec{E}$  ou  $\vec{B}$ , peut alors être décomposé comme la somme de deux composantes orthogonales. Soit une onde se propageant selon  $\vec{z}$  dans un repère orthonormé  $xyz$  :

$$\vec{E} = \vec{E}_\perp + \vec{E}_\parallel = \vec{E}_V + \vec{E}_H \quad (\text{A.7})$$

Avec :

$$\begin{aligned}\vec{E}_\perp(t, \vec{z}) &= E_{0x} \cos(\omega_c t - \vec{k} \cdot \vec{z} + \varphi_1(t)) \\ \vec{E}_\parallel(t, \vec{z}) &= E_{0y} \cos(\omega_c t - \vec{k} \cdot \vec{z} + \varphi_2(t))\end{aligned} \quad (\text{A.8})$$

Plusieurs cas se présentent alors. Considérons la différence de phase  $\delta\varphi = \varphi_2(t) - \varphi_1(t)$  entre les 2 composantes du champs électrique,  $\vec{E}_\perp$  et  $\vec{E}_\parallel$ .

Si  $\delta\varphi$  :

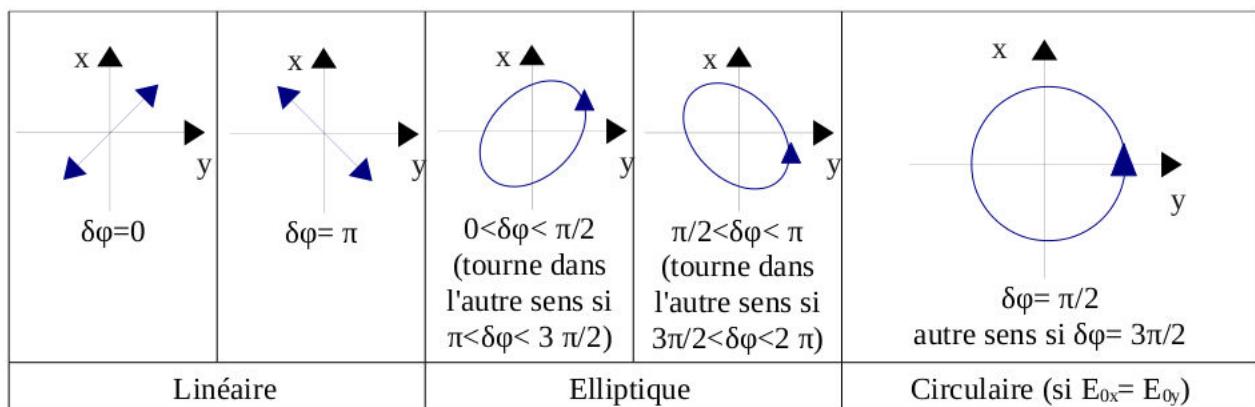


FIGURE A.2 – Différents cas de polarisation

Cependant, dans le cas de rayonnement naturel, les ondes ne sont pas polarisées. Il n'y a pas de corrélation entre  $\vec{E}_\perp$  et  $\vec{E}_\parallel$ , soit  $\langle \vec{E}_\perp \cdot \vec{E}_\parallel^* \rangle = 0$ .

On définit alors les paramètres de Stokes U et V comme étant la moyenne temporelle des corrélations au travers un angle solide  $d\Omega$ , dans un milieu d'impédance  $\eta$  :

$$U = \frac{2\Re\langle \vec{E}_\perp \cdot \vec{E}_\parallel^* \rangle}{\eta\Omega} = 0 \quad \text{et} \quad V = \frac{2\Im\langle \vec{E}_\perp \cdot \vec{E}_\parallel^* \rangle}{\eta\Omega} = 0 \quad (\text{A.9})$$

## A.2 Interaction onde-matière

Considérons maintenant le cas où l'onde est incidente à une surface. C'est justement le cas dans lequel se place l'étude lors des interfaces atmosphère-végétation-sol. Lorsqu'une onde est incidente à un plan, cela signifie qu'il y a discontinuité de la permittivité diélectrique entre deux milieux, et donc que l'on peut appliquer les deux lois de Snell-Descartes. Considérons alors le cas de la FIGURE A.3

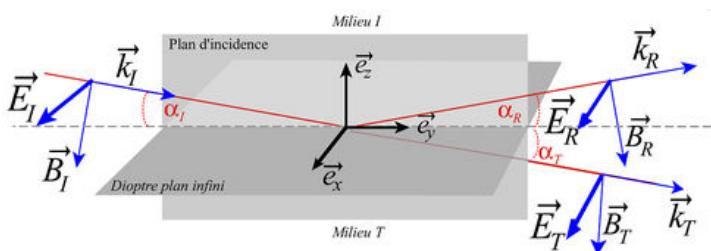


FIGURE A.3 – Interaction onde-matière

Soit une onde incidente I, issue d'un milieu d'indice  $n_I$ , de vecteur directeur  $\vec{k}_I$ , incidente avec un angle  $\alpha_I$ . Une partie de cette onde est réfléchie, selon la direction  $\vec{k}_R$ , et un angle  $\alpha_R$ . Une autre partie est alors transmise selon la direction  $\vec{k}_T$  et l'angle  $\alpha_T$ . Les lois de Snell-Descartes donnent alors :

$$\begin{aligned} \alpha_I &= \alpha_R \\ n_I \sin \alpha_I &= n_T \sin \alpha_T \end{aligned} \quad (\text{A.10})$$

avec  $n$  l'indice du milieu, rapport entre la vitesse de la lumière et la vitesse de phase de l'onde dans le milieu (c'est à dire l'efficacité de propagation dans le milieu), proportionnelle à sa constante diélectrique  $\varepsilon_r$ .

$$n = \frac{c}{V_\varphi} = \sqrt{\frac{\varepsilon \mu}{\varepsilon_0 \mu_0}} = \sqrt{\varepsilon_r} \quad (\text{A.11})$$

De ces lois apparaissent les coefficients de Fresnel de réflectivité  $R_p$  (avec  $p$  le type de polarisation, verticale V ou horizontale H), dépendant de l'angle d'incidence  $\theta$  et de la constante diélectrique  $\varepsilon$  du milieu. Ces coefficients représentent la portion de champ réfléchi du rayonnement selon les 2 plans de polarisation :

$$R_H = \left[ \frac{\cos \theta - \sqrt{\varepsilon - \sin^2 \theta}}{\cos \theta + \sqrt{\varepsilon - \sin^2 \theta}} \right]^2 \quad R_V = \left[ \frac{\varepsilon \cos \theta - \sqrt{\varepsilon - \sin^2 \theta}}{\varepsilon \cos \theta + \sqrt{\varepsilon - \sin^2 \theta}} \right]^2 \quad (\text{A.12})$$

Et d'après la loi de conservation de l'énergie, tout ce qui n'est pas réfléchi est soit absorbé soit transmis :  $R_p + A_p + T_p = 1$

Cette réflexion est fortement corrélée à la structure de la surface. Les surfaces planes, où le rayonnement est purement spéculaire, renvoient le rayon selon la même intensité et dans une seule direction. Le rayonnement naturel, renvoie le rayon selon une direction principale mais l'intensité est altérée par la diffusion due à la rugosité de la surface. Et enfin, lorsque le rayonnement est complètement diffusé, la surface est dite *Lambertienne* (voir FIGURE A.4).

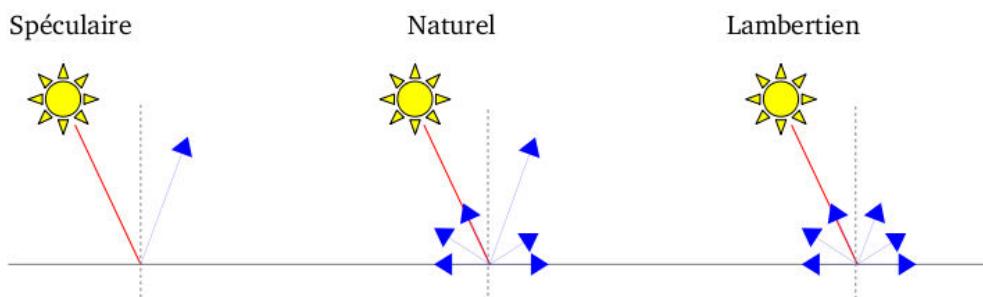


FIGURE A.4 – Différents types de réflexion à gauche, spéculaire, pas de diffusion ; au milieu, naturel, diffusion proportionnelle à la rugosité ; à droite, Lambertien, diffusion pure.

## A.3 Émissivité et température de brillance

Tout comme l'image du gradient de couleur d'un métal en fusion, la nature du rayonnement émis par un matériau est corrélée à sa température. L'intensité de ce rayonnement, à une fréquence donnée, varie selon la nature et la température du matériau. Cette intensité est représentée par la notion de brillance (ou luminance)  $L_f$ , ou  $L_\lambda$ , qui définit la quantité d'énergie émise à une fréquence donnée et par unité de surface ( $d\omega$ ) (voir FIGURE A.5).

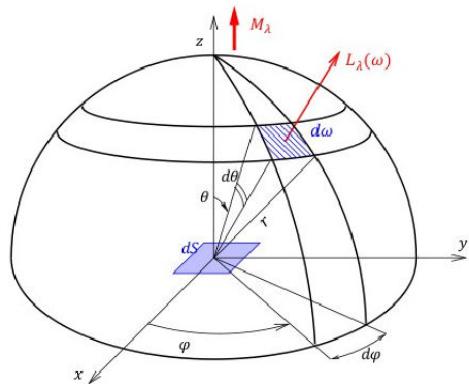


FIGURE A.5 – La luminance *quantité d'énergie, à une fréquence donnée, par unité de surface*

D'après la loi de Kirchhoff, un corps noir est un solide absorbant tout le rayonnement qu'il reçoit (d'où la couleur noire). En se basant sur cet objet idéal et sur le fait que cet objet émet de façon isotrope (rayonnement indépendant de la direction), Planck a calculé l'intensité du rayonnement émis en fonction de sa température  $L_f$  (en  $\text{W.m}^{-2}.\text{sr}^{-1}.\text{Hz}^{-1}$ ) pour un corps de température  $T$  comme étant :

$$L_f = \frac{2hf^2}{c^2} \cdot \frac{1}{e^{\frac{hf}{kT}} - 1} \quad (\text{A.13})$$

Avec :

- $h$  : constante de Planck ( $6,63 \cdot 10^{-34} \text{ J}$ )
- $k$  : constante de Boltzmann ( $1,38 \cdot 10^{-29} \text{ J.K}^{-1}$ )

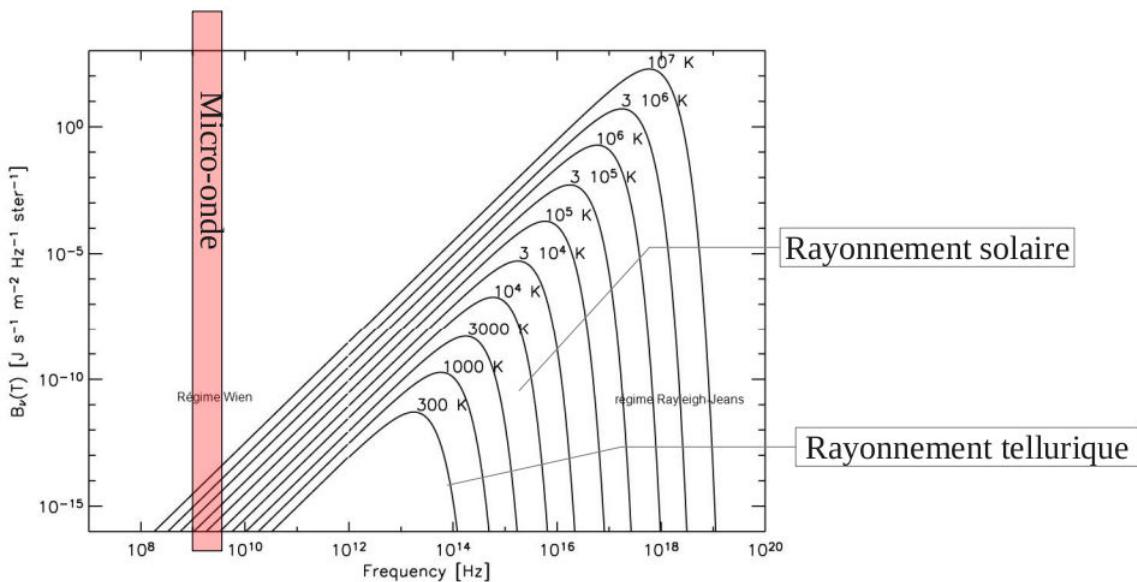


FIGURE A.6 – Intensité spectrale en fonction de la température

L'évolution de l'intensité de cette brillance en fonction de la fréquence et de la température du solide rayonnant est représentée sur la FIGURE A.6. On remarque alors que dans les micro-ondes, zones rouge de la FIGURE A.6, le rayonnement solaire ( $\approx 6000\text{K}$ ) peut être négligé dans

le cas où l'on ne le vise pas directement. En effet, les radiations solaires reçues par la Terre sont comprises dans un très petit angle solide. Cela permet aux faibles valeurs de rayonnement tellurique ( $\approx 300\text{K}$ ) de ne pas être recouvertes par le rayonnement solaire.

L'ÉQUATION (A.13) peut être approximée par la loi de Rayleigh Jeans qui stipule que dans les basses fréquences ( $hf/kT \ll 1$ ), l'émission d'un corps noir  $L_{fn}$  est directement proportionnelle à sa température  $T_n$  selon la relation :

$$L_{fn} = \frac{2k}{\lambda^2} \cdot T_n = C \cdot T_n \quad (\text{A.14})$$

La notion de température de brillance  $T_B$  est définie à partir de cette expression :

$$T_B = \frac{L_f}{C} \quad (\text{A.15})$$

Ainsi, pour un corps noir absorbant tout le rayonnement,  $T_{Bn} = T_B$

On peut alors définir la notion d'émissivité comme étant la partie de rayonnement réémis après absorption. C'est à dire le rendement énergétique, 1 si tout est réémis, 0 si tout est absorbé. Dans le cas d'un corps qui n'est pas absorbant parfait, on a alors :

$$T_B = e \cdot T \quad (\text{A.16})$$

Cette émissivité est propre à chaque matériau et dépend de la température, de la fréquence et de la direction observée. Elle est par exemple de 1 pour un corps noir, 0,99 pour la neige et 0,8 pour le gazon.

À l'équilibre thermodynamique, on considère que tout ce qu'absorbe un matériau est réémis, soit  $A_p = e$ , et que pour un milieu opaque à la fréquence observée, la transparence  $T_P = 0$ , ainsi :

$$R_p = 1 - A_p = 1 - e \quad (\text{A.17})$$

De l'ÉQUATION A.17, on retiendra la dépendance de l'émissivité  $e$  à la réflectivité  $R_p$ , et donc à la constante diélectrique  $\varepsilon$ . (voir ÉQUATION (A.12)).

Dans le cas de la biosphère, cette variation de constante diélectrique est fortement corrélée au paramètres physiques du milieu. Par exemple, dans le cas du sol, ses proportions en argile, sable et limon conditionneront la capacité qu'il aura à retenir les particules d'eau mais aussi ses capacités de stockage d'eau. Or c'est justement cette capacité qui rend le sol plus ou moins humide et donc modifie sa constante diélectrique, et au final son émissivité. L'émissivité évolue donc en fonction du contenu en eau. En effet, plus il y a d'eau dans la feuille ou le sol, moins il y a d'émissivité, et donc une température de brillance plus faible. Cette dynamique de variation est d'autant plus forte à 1,4GHz (FIGURE A.7).

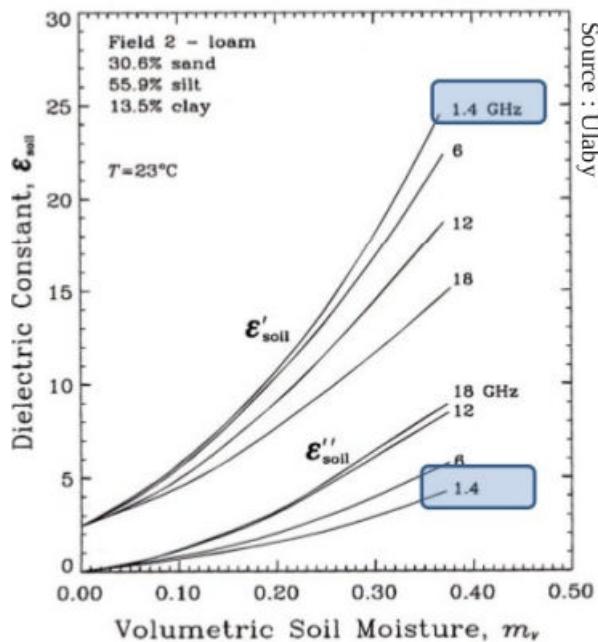


FIGURE A.7 – Sensibilité de la constante diélectrique à plusieurs fréquences en fonction de l'humidité du sol

# Annexe B

## De la mesure de rayonnement à l'humidité du sol, description de l'inversion d'humidité

Dans cette annexe nous allons voir comment passer des mesures de rayonnement micro-onde mesurés par SMOS au valeurs d'humidité du sol. Une fois le rayonnement micro-onde mesuré sur différents angles, un modèle simulant la mesure SMOS est utilisé, le L-MEB. Dans un second temps, nous verrons le processus d'inversion d'humidité.

### B.1 le L-MEB

Ce modèle est basé sur 3 sources principales de rayonnement : l'atmosphère,  $T_{Atm}$ , la végétation,  $T_{Veg}$ , et le sol  $T_{Sol}$ . Chacune de ces sources rayonnent. Le rayonnement traverse des milieux différents en fonction de la trajectoire qu'il parcourt (FIGURE B.1). On considérera les milieux homogènes d'un point de vue constante diélectrique et permittivité comme plans et infiniment étendus. On se retrouve ainsi dans une configuration avec des milieux de natures différentes et des changements de propriétés diélectriques délimités par des interfaces. Il y a donc des phénomènes d'absorption, de réflexion et de réfraction (voir ANNEXE A.2).

Chaque milieu est caractérisé par ses propriétés physiques et est susceptible de modifier la nature de la propagation du rayonnement, en l'atténuant, en le dépolarisant, etc. Ainsi, à partir de ces 3 sources de rayonnement, on peut calculer le flux de rayonnement observé par SMOS : **Équation du bilan radiatif :**

$$TB_{Total} = \underbrace{TB_{Atm} \cdot (1 - \omega_{Veg})}_{1} + \underbrace{TB_{Atm} \cdot \gamma_{Veg} \cdot 2 \cdot (1 - e_{Sol})}_{2} + \underbrace{TB_{Sol} \cdot \gamma_{Veg}}_{3} + \underbrace{TB_{Veg}}_{4} + \underbrace{TB_{Veg} \cdot (1 - e_{Sol}) \cdot \gamma_{Veg}}_{5} \quad (B.1)$$

- **1** : Réflexion du rayonnement atmosphérique sur la canopée ;
- **2** : Le rayonnement atmosphérique pénètre la végétation, la traverse ( $\gamma_{Veg}$ ) une fois, se reflète sur le sol ( $1-e_{Sol}$ ), puis retraverse la couche de végétation ;
- **3** : Le rayonnement provenant du sol traverse la couche de végétation ( $\gamma_{Veg}$ ) ;
- **4** : La végétation rayonne directement en direction de SMOS ;

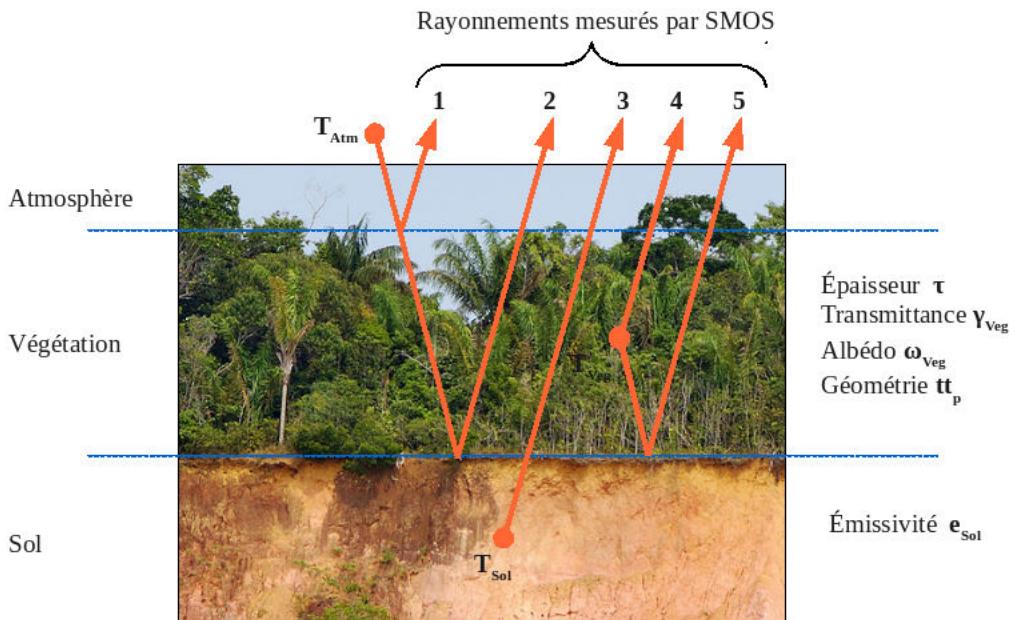


FIGURE B.1 – Le L-MEB : Basé sur 3 sources principales : le sol, la végétation et l'atmosphère, le L-MEB permet de simuler le rayonnement émis par un scénario observée par SMOS

- 5 : La végétation rayonne en direction du sol, se reflète ( $1 - e_{Sol}$ ) puis traverse la couche de végétation ( $\gamma_{Veg}$ ).

En simulant l'équation (B.1) pour différents angles d'incidences, on peut alors reproduire des profils angulaires de température de brillance et étudier l'influence des différents paramètres sur l'allure de ces profils :

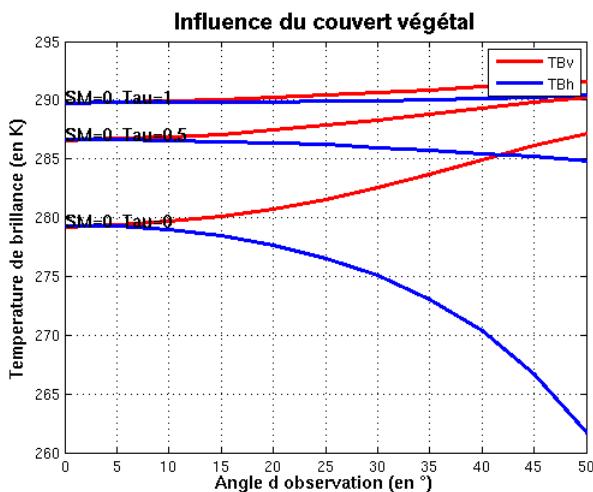


FIGURE B.2 – Réponse du L-MEB à l'augmentation du couvert végétal : plus  $\tau$  ( $Tau=\tau$ ) augmente, plus le rayonnement est fort

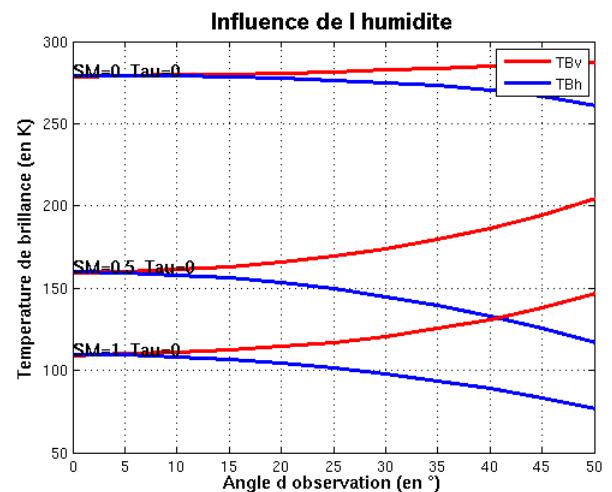
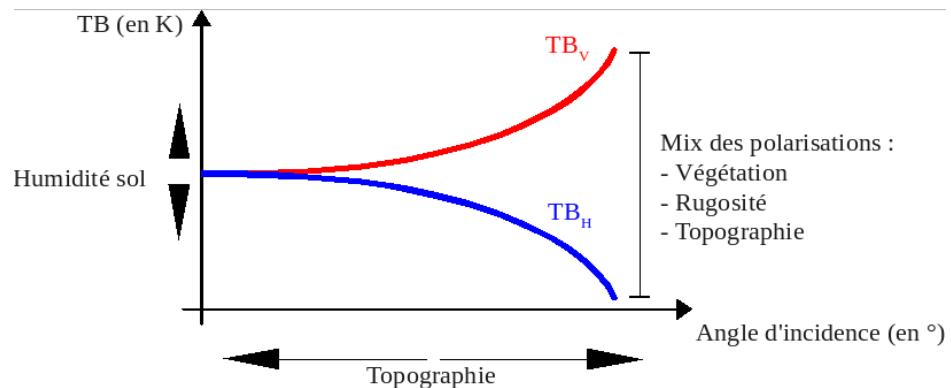


FIGURE B.3 – Réponse du L-MEB à l'augmentation d'humidité du sol plus l'humidité (SM) est forte, moins il y a de rayonnement

On remarque sur la FIGURE B.2 que si l'épaisseur du couvert végétal augmente ( $\tau$ ), la température globale augmente mais surtout qu'il y a une diminution de la différence de température entre les 2 polarisations pour les grands angles. Si on augmente l'humidité du sol (SM pour Soil

Moisture), FIGURE B.3, les températures de brillance diminuent, car la constante diélectrique augmente et donc l'émission diminue. Pour synthétiser :



La FIGURE B.4 représente l'influence des paramètres du modèle sur l'allure des profils de températures de brillance. À savoir, plus l'humidité est élevée, moins la température de brillance sera grande. La végétation et la rugosité engendrent des mélanges de polarisation. La topographie décale les profils angulaires dans le cas d'une orientation de la facette dans le plan d'observation (erreur angulaire), ou bien mélange les polarisations dans le cas d'une rotation autre.

## B.2 L'inversion d'humidité

L'opération d'inversion revient à comparer le modèle issu de l'équation (B.1), aux mesures SMOS et à ajuster les paramètres physiques du modèle pour essayer d'expliquer au mieux les mesures :

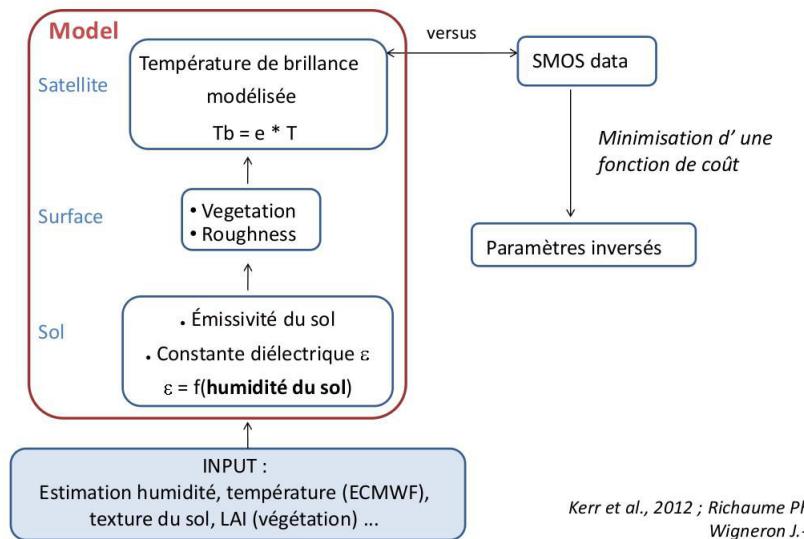


FIGURE B.5 – Schéma du processus d'inversion : *À partir de données géophysiques (température, rugosité,..), le modèle simule le rayonnement susceptible d'être mesuré par SMOS. En utilisant une fonction de coût, et en la minimisant, il est alors possible de remonter jusqu'à certains paramètres physiques tels que l'humidité du sol ou l'épaisseur de végétation.*

Pour ajuster le modèle aux mesures, l'opération à effectuer est de minimiser une fonction

de coût (B.2), et de trouver les minimums locaux des paramètres que l'on veut inverser :

$$\sum \frac{(TB_{SMOS} - TB_{Simul})^2}{\sigma_{Mesure}} + \sum \frac{(Parametre_{Cherch} - Parametre_{Initial})^2}{\sigma_{Prcision \ inversion}} \quad (B.2)$$

Avec :  $\sigma$  la contrainte de précision sur les paramètres inversés.

#### Simulation fractionnée :

Lorsque SMOS fait une mesure, le champ de vue est pondéré par le gain synthétique de l'antenne. Or la scène observée a une surface d'environ 40x40km, et donc n'est jamais homogène, elle peut être composée, comme sur la FIGURE B.6, d'une fraction de forêt, une autre d'eau libre, une autre de sol nu, et un peu de végétation basse. Le modèle L-MEB simule alors le profil pour chacune des fractions supposées vues par SMOS. Chacune de ces simulations étant ainsi configurée pour modéliser au mieux le milieu observé. Cependant, l'inversion des paramètres ne se fait que sur la fraction majoritaire [Kerr et al., 2012] [Kerr et al., 2011] (la forêt dans le cas de la FIGURE B.6).

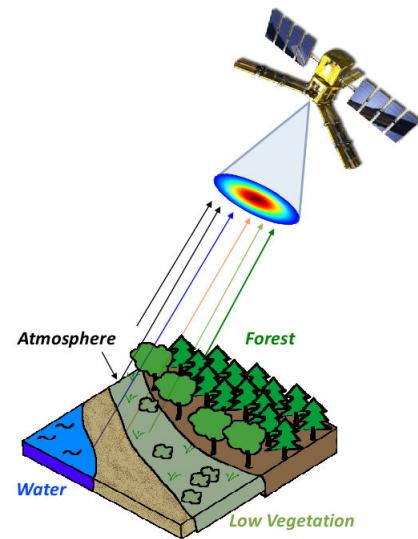


FIGURE B.6 – Observation d'une scène hétérogène

# Annexe C

## Listing SURFEX

```
&NAM_FRAC          LECOCLIMAP = T
/
&NAM_COVER         YCOVER      = 'ECOCLIMAP_I_GLOBAL',
                    YCOVERFILETYPE = 'DIRECT'
/
&NAM_PGD_GRID      CGRID       = 'LONLAT REG '
/
&NAM_LONLAT_REG    XLONMIN   = 1.5937,
                    XLONMAX   = 1.853,
                    XLATMIN   = 9.4594,
                    XLATMAX   = 9.661,
                    NLON      = 1           ,
                    NLAT      = 1           ,
/
&NAM_PGD_SCHEMES  CNATURE    = 'ISBA'     ,
                    CSEA       = 'NONE'    ,
                    CTOWN      = 'NONE'    ,
                    CWATER     = 'NONE'    ,
/
&NAM_ZS             XUNIF_ZS  = 100.
/
&NAM_ISBA           YCLAY      = "clay_fao",
                    YSAND      = "sand_fao",
                    YCLAYFILETYPE = "DIRECT",
                    YSANDFILETYPE = "DIRECT",
                    XUNIF_RUNOFFB = 0.5,
                    CISBA      = 'DIF'     ,
                    CPHOTO     = 'NON'    ,
                    NPATCH     = 3         ,
                    NGROUND_LAYER = 14    ,
                    CPEDO_FUNCTION='CH78'
/
&NAM_IO_OFFLINE    LPRINT    = T           ,
                    LWRITE_COORD = F           ,
                    CFORCING_FILETYPE = 'ASCII' ,
```

---

```
          CSURF_FILETYPE =      'NC'      ,
          CTIMESERIES_FILETYPE = 'NETCDF'   ,
          XTSTEP_OUTPUT = 3600.           ,
          LRESTART=T,
          XTSTEP_SURF = 3600.
/
&NAM_PREP_SURF_ATM NYEAR  =2010,
                     NMONTH =1,
                     NDAY   =1,
                     XTIME  =3600.
/
&NAM_PREP_SEAFLUX XSST_UNIF = 285.,
                     NYEAR  =2010,
                     NMONTH =1,
                     NDAY   =1,
                     XTIME  =3600.
/
&NAM_PREP_WATFLUX XTS_WATER_UNIF = 285.,
                     NYEAR  =2010,
                     NMONTH =1,
                     NDAY   =1,
                     XTIME  =3600.
/
&NAM_PREP_TEB      XTI_ROAD= 285.,
                     XTI_BLD = 285.
                     XTS_ROAD= 285.
                     XTS_ROOF= 285.,
                     XTS_WALL= 285.,
                     XWS_ROAD= 0.,
                     XWS_ROOF= 0.,
                     NYEAR  =2010,
                     NMONTH =1,
                     NDAY   =1,
                     XTIME  =3600.
/
&NAM_PREP_ISBA    XHUG_SURF = -0.8,
                     XHUG_ROOT =-0.8,
                     XHUG_DEEP = -0.8,
                     XTG_SURF = 300,
                     XTG_ROOT = 300,
                     XTG_DEEP = 300,
                     NYEAR  =2010,
                     NMONTH =1,
                     NDAY   =1,
                     XTIME  =3600.
/
&NAM_PREP_ISBA_SNOW CSNOW = '3-L'
/
```

---

```
&NAM_DIAG_SURFn      LSURF_BUDGET = T      ,
                      N2M      = 2      ,
                      LCOEF    = F      ,
                      LSURF_VARS = F      ,
                      LSURF_BUDGETC = F
/
&NAM_DIAG_SURF_ATMn   LFRAC      = F
/
&NAM_DIAG_ISBAn       LPGD      = F , 
                      LSURF_EVAP_BUDGET = F ,
                      LSURF_MISC_BUDGET = F ,
                      LWATER_BUDGET = F
/
&NAM_SGH_ISBAn        CKSAT = 'SGH',
                      CRUNOFF='DT92'
/
```



## Annexe D

# Les forçages atmosphériques

La capacité des modèles à reproduire une variable définie est intimement liée à l'incertitude sur les données d'entrées. Dans cette étude nous utiliserons des forçages atmosphériques extraits de la base de données MERRA ([[Gelaro et al., 2017](#)]. MERRA (Modern-Era Retrospective analysis for Research and Applications) est un produit de données atmosphériques dérivé assimilées par une grande quantité de satellites dans le Atmospheric Data Assimilation System (ADAS) de la NASA. La résolution est de  $1/2 \times 1/3^\circ$ , une simple interpolation linéaire est appliquée pour ramener la résolution à  $0.25 \times 0.25^\circ$  et permettre ainsi de fournir le forçage atmosphérique de SURFEX.

Les forçages utilisés pour les sites du Niger et du Bénin sont représenté Figure D.1 et Figure D.2. Des scores statistiques ont été calculés pour chacun de ces groupes de forçage, voir Tableau D.1. Analysons globalement l'allure de ces forçages (dans l'ordre d'apparition sur les Figure) :

- Les rayonnements solaire incident dans les grandes longueurs d'onde (Infrarouge) ont une forte saisonnalité en fonction de la saison des pluies/saison sèche. Durant la saison des pluies, la forte nébulosité explique cette augmentation de rayonnement incident dans les grandes longueurs d'onde, en effet les nuages réémettent fortement dans ce spectre. Les différences sont relativement faible entre les site du Niger et du Bénin.
- Les rayonnements dans les petites longueurs d'onde ont une saisonnalité en fonction de la saison des pluies/saison sèche, mais aussi un cycle diurne. Durant la saison des pluies, la forte nébulosité explique la diminution de rayonnement direct du Soleil sur le sol. Le cycle diurne explique le retour à  $0 \text{ W.m}^{-2}$  des valeurs la nuit.
- La pression à 2m du niveau du sol est la combinaison de la saisonnalité et du fait que la pression est plus faible pendant la mousson. Les différences de min/max sont assez importantes entre le Bénin et le Niger.
- La température à 2m du niveau du sol est la combinaison de la saisonnalité et du fait qu'il fait plus froid pendant la mousson. Il fait plus chaud de 2K (ou  $2^\circ\text{C}$ ) en moyenne sur le site du Niger que sur le site du Bénin. On remarquera le fort maximum de  $45.52^\circ\text{C}$  au Niger.
- L'humidité de l'air à 2m est faible pendant la saison sèche et haute pendant la saison des pluies. On remarquera que la saison sèche est bien plus prononcée au Niger avec un minimum qui dure plus longtemps qu'au Bénin.
- La direction du vent est elle aussi très influencée par la ZCIT. Avec un vent plutôt du Nord-Est pendant la saison sèche (entre  $0$  et  $100^\circ$ ), avec un vent chaud et sec nommé Harmattan, la montée de ZCIT modifie la direction globale des vents en venant du Sud-Ouest.

- 
- La vitesse du vent est forte pendant la saison sèche puis diminue pendant la mousson.
  - Le signal saisonnier est logiquement très marqué sur la pluviométrie. On retrouve pratiquement deux fois plus de pluie, en moyenne, au Bénin (0.437 mm/3h) qu'au Niger (0.226 mm/3h). Pour les cumuls annuels, ils sont en moyenne de 1200 mm pour le Bénin et de 600 mm pour le Niger. Au Niger, le cumul annuel peut aller de 400mm (en 2011) à 680mm (en 2015). Pour le Bénin, les plus faible cumul sont autour de 1050mm (2011 et 2013) et les plus fort à 1500mm (2010 et 2012).

TABLE D.1 – Statistiques sur les forçages atmosphériques utilisés, pour les sites du Bénin et du Niger.

	Bénin				Niger			
	Moy.	Std.	Min.	Max.	Moy.	Std.	Min.	Max.
<b>LW Radiation</b> <i>W.m<sup>-2</sup></i>	382.66	31.44	264.49	457.84	370.65	41.71	244.99	456.11
<b>SW Radiation</b> <i>W.m<sup>-2</sup></i>	216.54	291.24	0	1065	241.66	218.87	0	1089
<b>2m Air Pres.</b> <i>Pa</i>	101020	214.38	100120	101870	1000970	270.33	99280	102100
<b>2m Air Temp.</b> <i>K</i>	299.17	4.79	284.155	314.37	301.92	6.13	282.77	318.67
<b>2m Air Humi.</b> <i>kg.kg<sup>-1</sup></i>	0.0141	0.0044	0.0016	0.021	0.0101	0.0061	0.0007	0.021
<b>Wind Direct.</b> <i>°N</i>	164.09	80.77	0.0138	359.96	151.33	88.96	0.0481	359.99
<b>Wind Speed</b> <i>m.s<sup>-1</sup></i>	2.78	1.29	0.022	10.75	3.66	1.62	0.247	11.62
<b>Rainfall</b> <i>mm/3h</i>	0.437	2.27	0	48.47	0.226	1.8	0	44.29

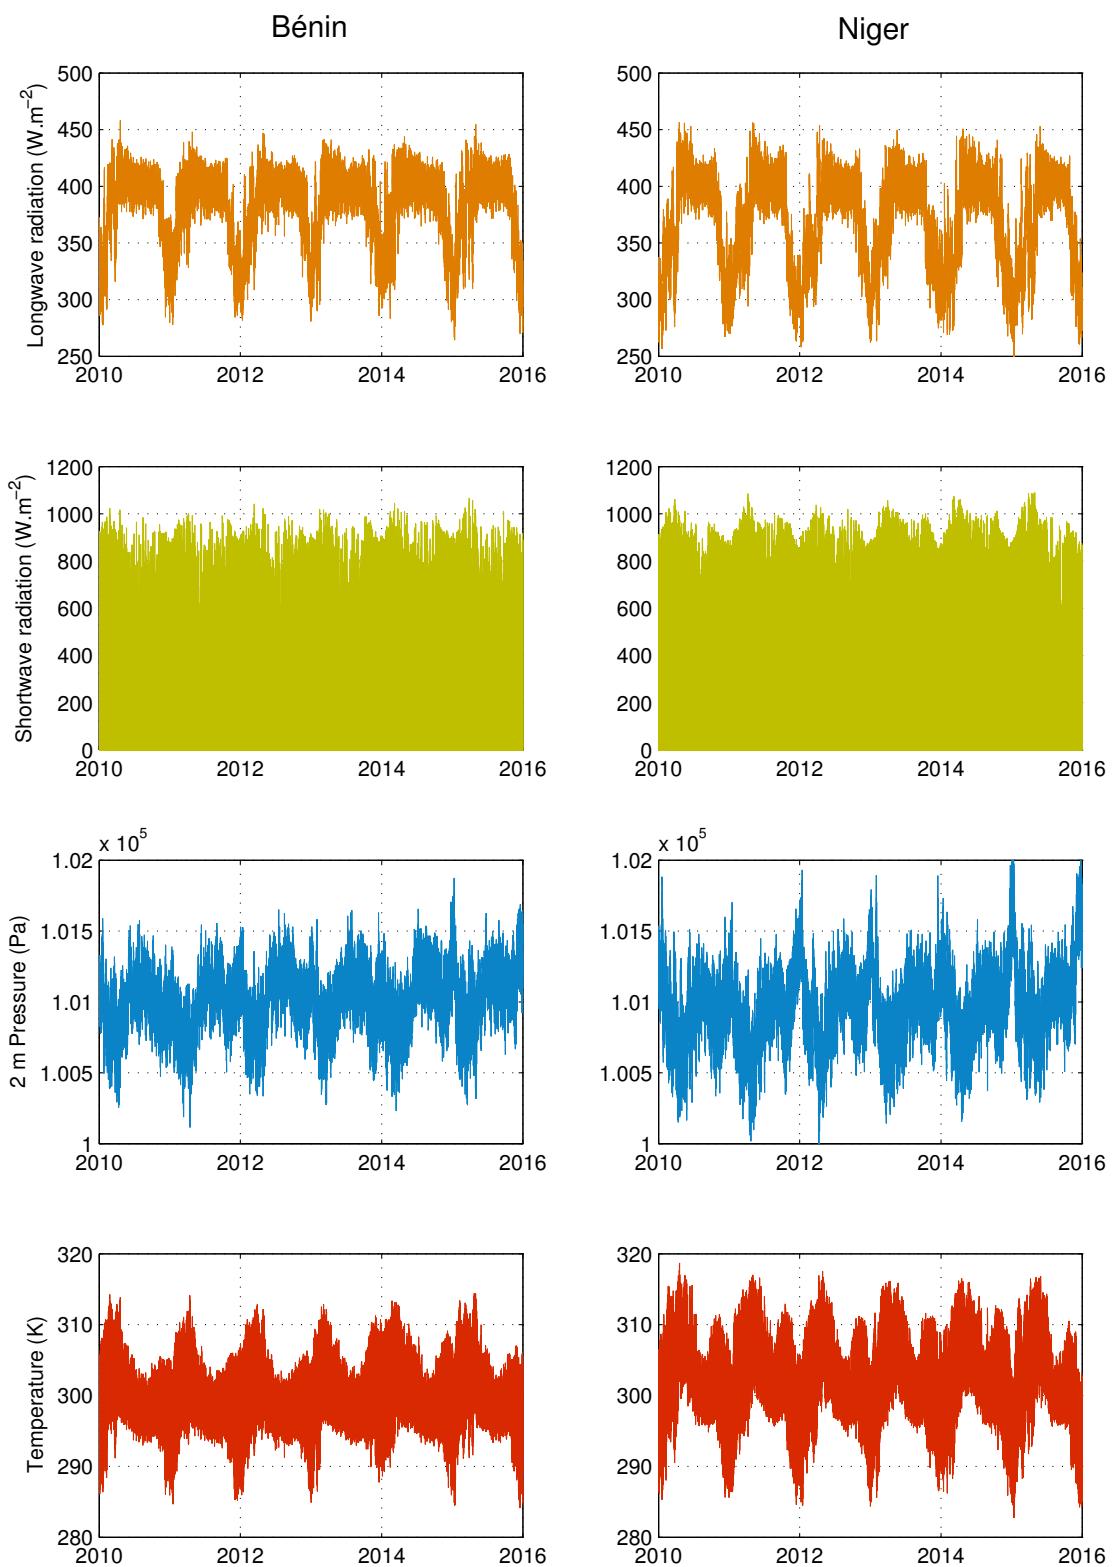


FIGURE D.1 – Forçages atmosphérique, issue des réanalyses MERRA, utilisés pour la modélisation sur le site du Bénin à gauche et le Niger à droite. Dans l'ordre les rayonnements incident grande et petite longueur d'onde, la pression atmosphérique à 2m et la température à 2m.

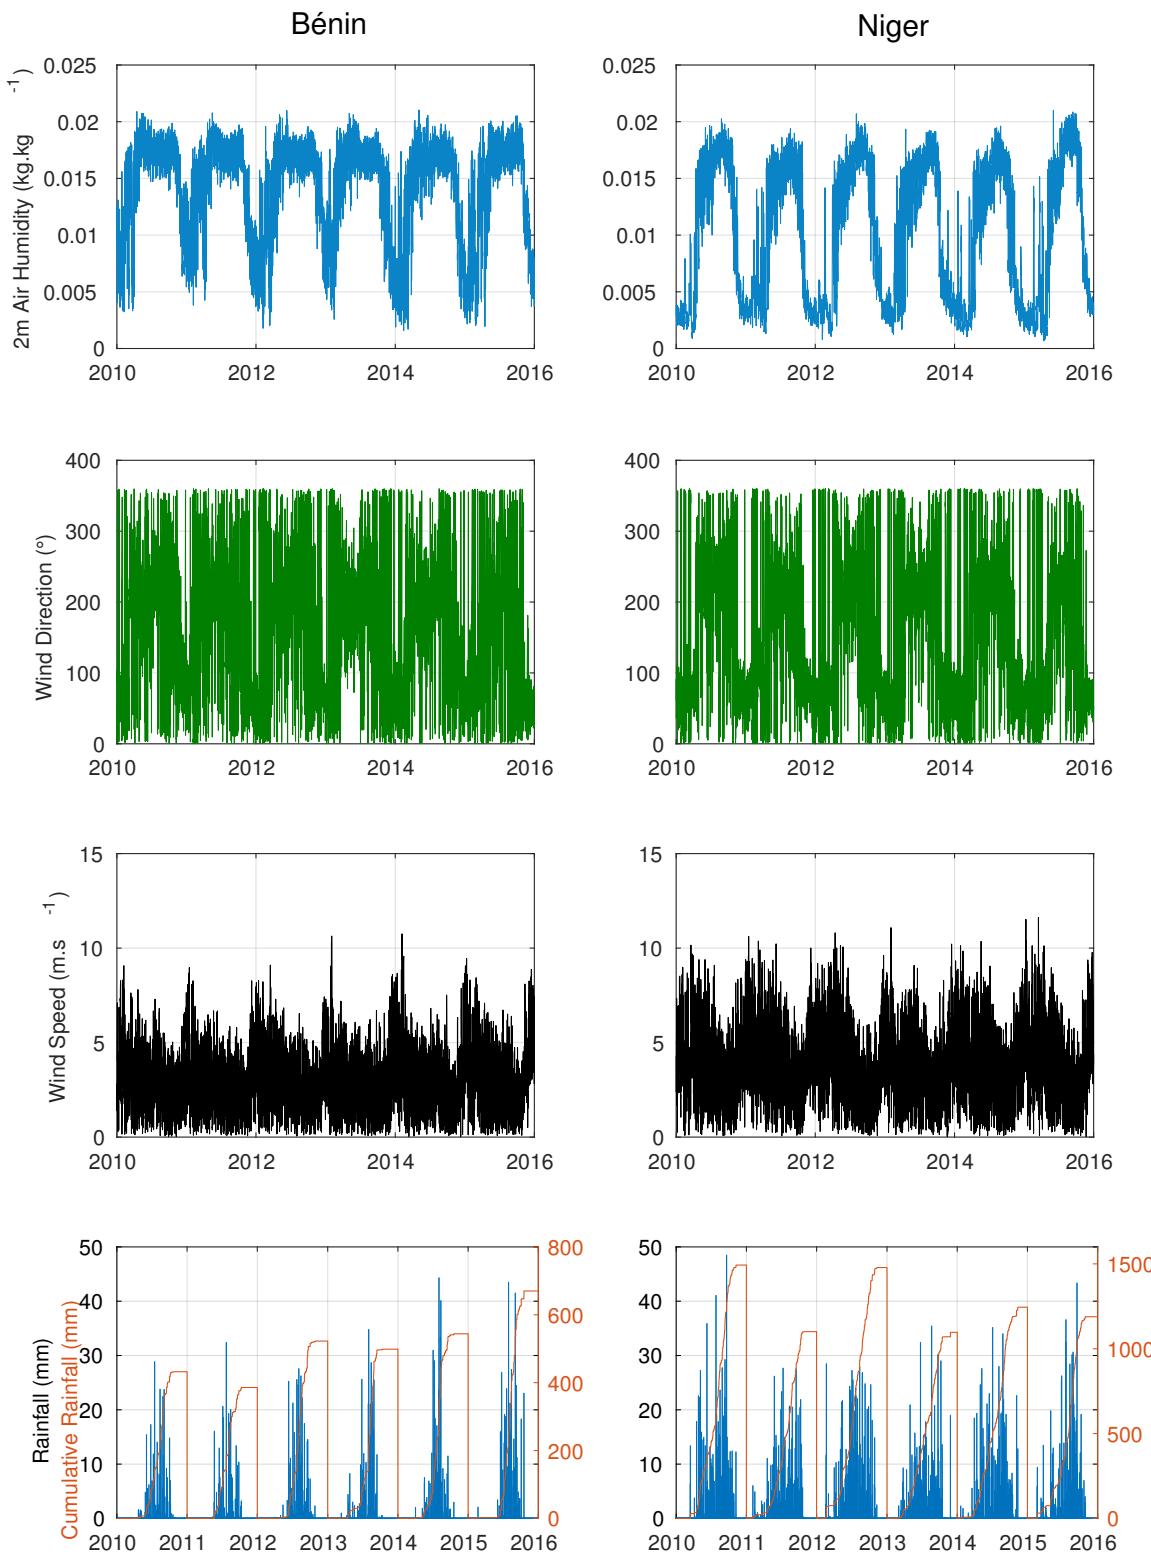


FIGURE D.2 – Forçages atmosphérique, issue des réanalyses MERRA, et les précipitations *in-situ* utilisés pour la modélisation sur le site du Bénin à gauche et le Niger à droite. Dans l'ordre l'humidité de l'air à 2m, la direction du vent, la vitesse du vent et les précipitation issues de mesures *in-situ*.

---

Ainsi, à partir des forçages décrit ci dessus, il est possible d'alimenter les modèles pour simuler l'humidité du sol.

Les valeurs des paramètres des modèles sont présentées ci dessous :

TABLE D.2 – Paramétrisation principale du SURFEX

(\* données FAO, \*\* issue de ECOCLIMAP et \*\*\* à partir de la fonction de pédotransfert : [Clapp and Hornberger, 1978])

	Niger	Bénin
Clay/Sand (en %) *	7.8/77	19/43
Sol nu/	46/	15/
Veg. basse/	51/	70
Veg.haute (en %) **	3	15
$\theta_{Sat}/\theta_{FC}/\theta_{Wilt}$ (en $m^3.m^{-3}$ ) ***	0.41/0.21/0.1	0.45/0.32/0.16

Avec la première ligne les proportions de d'argile et de sable, en seconde ligne les proportions de couverts proposé par ECOCLIMAP et en troisième ligne les caractéristiques hydrogéologique.



## Annexe E

# Analyse à l'échelle des districts administratifs

Dans cette partie un autre jeu de données de rendement est utilisé. Ce dernier, issue de la base de donnée CountryStat, fourni des données à l'échelle des districts administratifs pour les années 2000-2011. A partir des cartes d'anomalies d'humidité du sol  $\theta_{(t)}^{30cm}$ , dérivées sur les 2 périodes, chaque district a été pondéré par la carte 4.2. Ainsi, les anomalies d'humidités pour les 12 années ont été calculées pour chaque district. La Figure E.1 représente les régressions normalisées entre anomalies d'humidité du sol et de rendement pour chacun des districts.

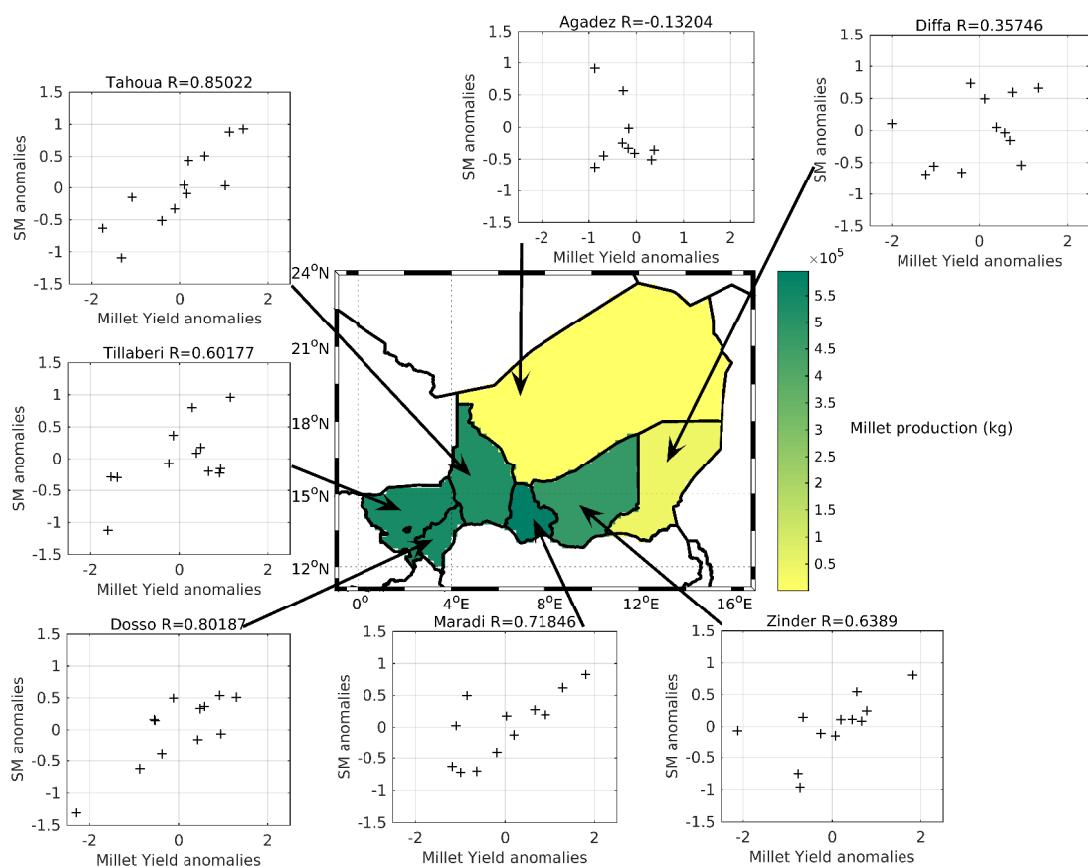


FIGURE E.1 – Les régressions ont été réalisées par districts administratifs (données CountryStat).

Les anomalies ont été normalisées pour n'étudier que les variations. La valeur de la corrélation ( $R$ ) est représentée à coté du nom du district. La couleur de la carte correspond à la production annuelle moyenne. Elle va de moins de 1000 tonnes pour la région d'Agadez, au nord, à plus de 550 000 tonnes pour la région de Maradi. On observe alors que lorsque la production est très faible, c'est le cas de Agadez et de Diffa, la relation est médiocre, avec respectivement un  $R$  à -0.13 et 0.36. Pour les districts avec une production plus importante, la relation est bien meilleure, jusqu'à 0.85 pour le district de Tahoua.

Les données de rendement par districts ont l'avantage de fournir un grand nombre de points, c'est à dire 7 fois 11 années. L'ensemble de ces 77 points ont été présentés Figure E.2, avec en abscisse, l'anomalie sur la période reproductive, et en ordonnée l'anomalie sur la période de remplissage de grain. La taille des points correspond à la production et la couleur à l'anomalie de rendement. On obtient alors un nuage de points, avec logiquement les mauvais rendements quand les 2 périodes sont sèches (points rouges en bas à gauche) et les bons rendements quand les 2 périodes sont humides (points verts en haut à droite). L'analyse des autres cadrants est intéressante car elle représente bien le fait que même si le nombre de grains est faible, résultat d'une période reproductive anormalement sèche (les 2 cadrants de gauche), mais que la période de remplissage est bonne, soit en haut à gauche, et bien les rendements semblent assez bons (majorité de points verts). Cependant si la période reproductive est bonne en humidité, on peut espérer un nombre de grain assez bon, mais que la période de remplissage est mauvaise, alors on obtiendra des rendements moyens (cadran en bas à droite).

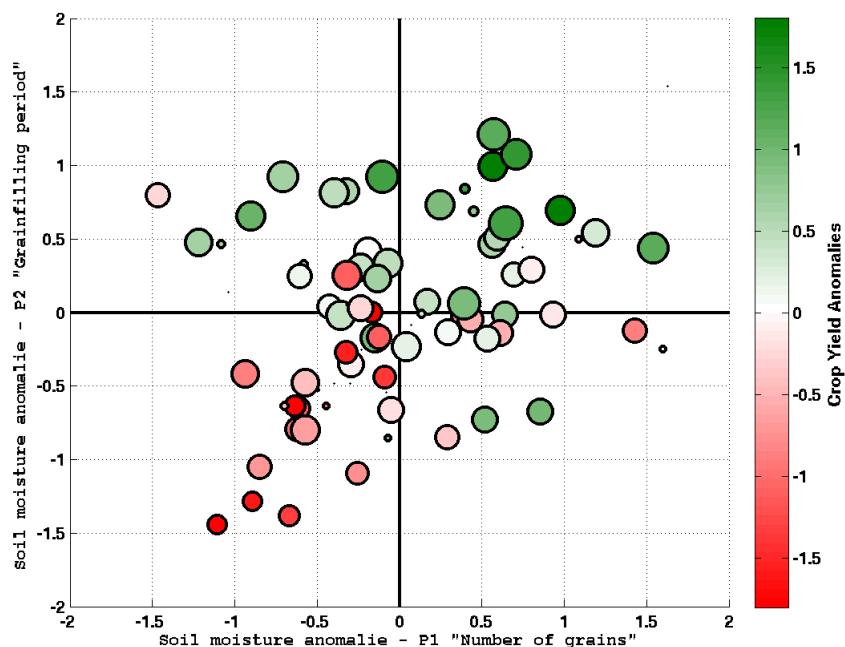


FIGURE E.2 – Analyse des anomalies normalisées d'humidité du sol pendant les 2 périodes phénologique identifiées comme critique pour les rendements de mil. La couleur des points correspond aux anomalies de rendement correspondantes, et la taille à la valeur absolue de la production.

# Annexe F

## Valorisations scientifiques

### F.1 Publications

F.1.1 Pellarin et al. 2015 : Three years of L-band brightness temperature measurments in a mountainous area : Topography, vegetation and snowmelt

See discussions, stats, and author profiles for this publication at: <https://www.researchgate.net/publication/297735920>

# Three years of L-band brightness temperature measurements in a mountainous area: Topography, vegetation...

Article in *Remote Sensing of Environment* · February 2016

DOI: 10.1016/j.rse.2016.02.047

---

CITATIONS

3

READS

122

12 authors, including:



**Thierry Pellarin**

University Joseph Fourier - Grenoble 1

72 PUBLICATIONS 1,764 CITATIONS

[SEE PROFILE](#)



**François Gibon**

University Joseph Fourier - Grenoble 1

3 PUBLICATIONS 4 CITATIONS

[SEE PROFILE](#)



**Samuel Morin**

French National Centre for Scientific Research

156 PUBLICATIONS 2,265 CITATIONS

[SEE PROFILE](#)



**Mike Schwank**

GAMMA Remote Sensing AG AND Swiss Feder...

91 PUBLICATIONS 1,407 CITATIONS

[SEE PROFILE](#)

Some of the authors of this publication are also working on these related projects:



Snow grain shape [View project](#)



MicroVegSnow Project [View project](#)



Contents lists available at ScienceDirect

## Remote Sensing of Environment

journal homepage: [www.elsevier.com/locate/rse](http://www.elsevier.com/locate/rse)

# Three years of L-band brightness temperature measurements in a mountainous area: Topography, vegetation and snowmelt issues

T. Pellarin <sup>a,b</sup>, A. Mialon <sup>d</sup>, R. Biron <sup>a,c</sup>, C. Coulaud <sup>a</sup>, F. Gibon <sup>a</sup>, Y. Kerr <sup>d</sup>, M. Lafaysse <sup>e</sup>, B. Mercier <sup>a,b</sup>, S. Morin <sup>e</sup>, I. Redor <sup>a</sup>, M. Schwank <sup>f,g</sup>, I. Völksch <sup>h</sup>

<sup>a</sup> Univ. Grenoble Alpes, LTRE, F-38000 Grenoble, France

<sup>b</sup> CNRS, LTRE, F-38000 Grenoble, France

<sup>c</sup> IRD, LTRE, F-38000 Grenoble, France

<sup>d</sup> Centre d'Etudes Spatiales de la Biosphère (CESBIO), CNES CNRS IRD UPS, OMP, Toulouse, France

<sup>e</sup> Météo-France – CNRS, CNRM-GAME UMR 3589, Centre d'Etudes de la Neige, Grenoble, France

<sup>f</sup> Swiss Federal Research Institute WSL, Zürcherstrasse 111, 8903 Birmensdorf, Switzerland

<sup>g</sup> Gamma Remote Sensing AG, Worbrstrasse 225, 3073 Gümligen, Switzerland

<sup>h</sup> Karlsruhe Institute of Technology, IMK-IFU, Germany

## ARTICLE INFO

## Article history:

Received 31 July 2015

Received in revised form 17 February 2016

Accepted 19 February 2016

Available online xxxx

## ABSTRACT

L-band passive measurements (1.4 GHz) over continental areas are known to be related to surface soil moisture. Two satellite missions were recently launched to measure land surface emissions at this frequency band (SMOS—Soil Moisture and Ocean Salinity in 2009 and SMAP—Soil Moisture Active/Passive in 2015). In order to improve soil moisture retrievals from satellite data, ground-based radiometer systems operating at the same frequency were deployed over specified areas to investigate the L-band emission of various land covers under various climatological conditions. In this study, three years of L-band passive measurements from a radiometer installed on top of a steep mountain in the French Alps were analyzed and compared to L-band passive simulations. The innovative radiometer location led to large footprints due to the distance between the radiometer and the area under study. This experiment also produced microwave measurements affected by various potential difficulties typically encountered in SMOS/SMAP satellite missions: topography, heterogeneous footprints, dry/wet snow events, dew and vegetation litter. Based on *in situ* and modeling data, this paper investigates the potential of a radiative transfer model (L-band Microwave Emission of the Biosphere, L-MEB) to simulate L-band measurements and analyzes the differences with ELBARA observations. First, it was found that the topography generated a mixing of the horizontal and vertical polarizations. In addition, a large positive bias was found on ELBARA measurements (31 K and 12 K in horizontal and vertical polarizations respectively). Investigations showed that the sky reflection measured by the radiometer was partially substituted by land reflection coming from the surrounding topography. Second, the low-vegetation emission was investigated and highlighted the inability of the MODIS NDVI product to correctly represent the vegetation dynamics. Finally, dry snow conditions were found to have non-negligible impact at L-band and a particular signature was found during snow melting periods, with potential applications at the SMOS/SMAP spatial scales (~40 km).

© 2016 Elsevier Inc. All rights reserved.

## 1. Introduction

Since the launch of the European Space Agency (ESA) SMOS satellite mission (Soil Moisture and Ocean Salinity, Kerr et al., 2010) in November 2009, numerous studies have been devoted to assessing the performance of the Level 2 and 3 SMOS soil moisture products using *in situ* soil moisture stations at various locations (Peischl et al., 2012; Bircher, Skou, Jensen, Walker, & Rasmussen, 2012; Jackson et al., 2012; Louvet et al., 2015). To make more advanced assessments, some experimental sites were also designed to measure brightness temperature and soil moisture in order to evaluate the representativeness of SMOS soil moisture retrievals at a smaller spatial scale than that actually used in the mission. In this context, various long-term experiments were carried out using

tower-based L-band radiometers. One year before the SMOS launch, ESA proposed the setting up of three L-band radiometers (ELBARA-II systems) for land or sea, local, long-term observations. In 2009, three ELBARA-II systems were installed. The first (Schwank et al., 2010) was near Valencia, Spain (Wigneron et al., 2012 and Schwank et al., 2012), on a site with mainly natural Mediterranean vegetation, including vineyards and other agricultural fields; the second was deployed in the boreal and subarctic region (Finland) to study the effects of the soil freeze/thaw process on the L-band signature (Rautiainen et al., 2012; Lemmetynen et al., 2015; Rautiainen et al., 2015); and the third was on an experimental farm in southern Germany over a temperate agricultural area (Schlenz, dall'Amico, Loew, & Mauser, 2012; dall'Amico, Schlenz, Loew, & Mauser, 2012). Other L-band radiometers

were also deployed in various locations, such as Antarctica (Macelloni et al., 2013), the South-West of France (de Rosnay et al., 2006), Belgium (Jonard et al., 2011) and Germany (Jonard et al., 2015). Lastly, various L-band airborne radiometric experiments were conducted (Zribi et al., 2011; Albergel et al., 2011; Bircher Skou & Kerr, 2013; Skou, Misra, Balling, Kristensen, & Sobjaerg, 2010; Rudiger, Walker, & Kerr, 2011).

Ground-based radiometer experiments provided brightness temperature measurements over a relatively small area (usually 5 to 20 m<sup>2</sup>) due to the proximity of the radiometer (tower of 5 m in Finland and 17 m in Valencia) and the antenna field of view ( $\approx 24^\circ$  at  $-10$  dB sensitivity, ELBARA-II). These experiments were dedicated to analyzing specific soil and vegetation microwave emissions in some particular climatic regions. In contrast, airborne radiometric experiments were able to acquire microwave measurements over large areas in order to investigate the spatial variability of the soil moisture within an SMOS pixel (about 43 km). The main drawbacks of airborne experiments are their almost prohibitive cost compared to ground-based experiments, and the usually restricted possibilities for verifying the statistics obtained for the overflow footprints due to the limited availability of *in situ* information.

An alternative to airborne experiments is to install a radiometer on top of a steep mountain in order to obtain continuous measurements over a large footprint area (comparable in size to that of airborne experiments). In 2011, one ELBARA-II radiometer was installed in the Vercors region of the French Alps at 1585 m above sea level in order to acquire L-band passive measurements of an area located 600 m below. The area studied was composed of grassland, and broadleaf and coniferous forests. It offered various climatological conditions such as dry/wet snow events, soil freezing and dew events. In addition, the selected site was strongly affected by the topography.

This experiment was also designed to investigate potential improvements of the SMOS L2SM algorithm since the current version is designed to retrieve soil moisture over the dominant kind of land cover at the pixel scale (Kerr et al., 2010). In addition, there is currently no SMOS soil moisture retrieval on topographic areas and under snow conditions (these areas are masked prior to the retrieval process).

The objective of the present paper is to analyze three years of L-band passive measurements together with coinciding *in situ* measurements and modeling data and to focus on three main topics: the topography, which plays a significant role in passive microwave remote sensing (Utku & Le Vine, 2011); the dynamics of the two main vegetation land covers on this site (grassland and forest); and the impact of snow cover on the brightness temperature measurements at L-band, particularly during snow melting periods.

## 2. Experimental setup and measurements

The Vercors region is located in the western part of the French Alps near the city of Grenoble. This mountainous, limestone region has many vertical cliffs. One of these was chosen in 2011 to receive the ELBARA-II system. This site was also selected in order to allow rapid access to the radiometer location at all times, either by car (most of the year) or by using the ski resort facilities in winter. The radiometer coordinates were 45.1304°N, 5.4913°E, alt = 1585 m. Five *in situ* soil moisture stations were installed in the target area in 2009, followed by a meteorological station in 2010.

### 2.1. ELBARA-II measurements

The ELBARA-II system is a Dicke-type radiometer operating at 1400–1427 MHz (L-band). It is equipped with a Pickett-horn antenna with two ports, one for horizontal (H) and one for vertical (V) polarization (Schwank et al., 2010). The antenna diameter is 1.4 m and its length is 2.7 m. The beam widths are  $\pm 6^\circ$  around the main antenna direction at  $-3$  dB,  $\pm 9^\circ$  at  $-6$  dB, and  $\pm 12^\circ$  at  $-10$  dB.

The ELBARA-II radiometer was installed at its operational location in the Vercors site on June 24th, 2011 and the experiment ended on December 12th, 2014. After a short test period of the three solar panels, the operational experiment started on August 20th, 2011. Brightness temperature measurements at horizontal and vertical polarizations were obtained every 30 min for five observation angles ( $55^\circ$ ,  $60^\circ$ ,  $65^\circ$ ,  $70^\circ$ ,  $75^\circ$ ) relative to the nadir (Fig. 1). The footprint of measurements ranged from 120,800 m<sup>2</sup> to 166,000 m<sup>2</sup> (at 3 dB) depending on the angle of incidence. In addition, once a week, external calibration sky measurements were performed for one hour, starting at 12:00 UTC at  $135^\circ$  relative to nadir (West direction) to recalibrate the Active Cold Source (ACS) and to check the “health” of the radiometer. Analysis of the sky measurements confirmed the excellent temporal stability of the ELBARA-II radiometer during the approximately three-year campaign performed at the Vercors site (Fig. 2). The average values were 4.44 and 4.46 K respectively for H and V polarizations and the standard deviation values were 0.27 and 0.29 K.

Similarly, problems internal and external to the instrument and affecting the quality of the measured brightness temperature were analyzed in detail by Schwank, Wiesmann, and Wegmüller (2014), in order to identify and eliminate outlying brightness temperature measurements from the time-series. Instrument internal distortions could occur because of deficient stabilization of the actual radiometer internal temperature with respect to the corresponding set-point temperature. These events were present during times of little incident solar radiation, when insufficient electrical power was generated to accurately stabilize the instrument temperature. External distortions were associated with non-thermal emissions of the scenes observed (radio frequency interferences, RFI). This procedure resulted in about 25% of the ELBARA-II measurements being rejected.

### 2.2. In situ measurements

The target area is presented in Fig. 3-a with a picture taken from the radiometer location. The target area has three kinds of vegetation: grassland and coniferous forest located on the East side of the valley and broadleaf forest on the west. *In situ* soil moisture and soil temperature measurements were set up prior to the ELBARA-II radiometer installation at various locations in the target area. Four stations were installed in the grassland area and one in the broadleaf forest. Micro-acquisition stations were Onset HOBO H21 002 with four inputs. Soil moisture probes were Decagon impedance sensors type ECH2O EC20 (Fig. 3-b). On each of the five sites, two soil moisture probes were installed at 5 cm depth. The other two inputs were used to record either soil temperature at 10 and 40 cm depth or soil moisture at 20 and 50 cm depth. Finally, meteorological measurements were obtained at the Grassland2 site (air temperature, air specific humidity, atmospheric pressure and precipitation since November 2011 (Fig. 3-c)).

#### 2.2.1. Soil moisture

Soil moisture measurements were automatically obtained at a 30-min time step. Fig. 4 presents the evolution of the surface soil moisture (5 cm depth) during the ELBARA-II Vercors experiment from June 2011 to December 2014, and daily rainfall measurements since the installation of the meteorological station in November 2011. All soil moisture sensors located at 5 cm depth are plotted in Fig. 4 (i.e. min/max and mean) separately for the grassland (gray) and forest (green) sites. The averaged values (black curves) for the grassland and the forest site are plotted separately and the overall variability of the two time-series is presented with the minimum and maximum values of all sensors. It can be observed that soil moisture is generally 10% lower under broadleaf forest than under grassland except during some short periods in summer. This is mostly due to the rain being intercepted by the vegetation (over- and

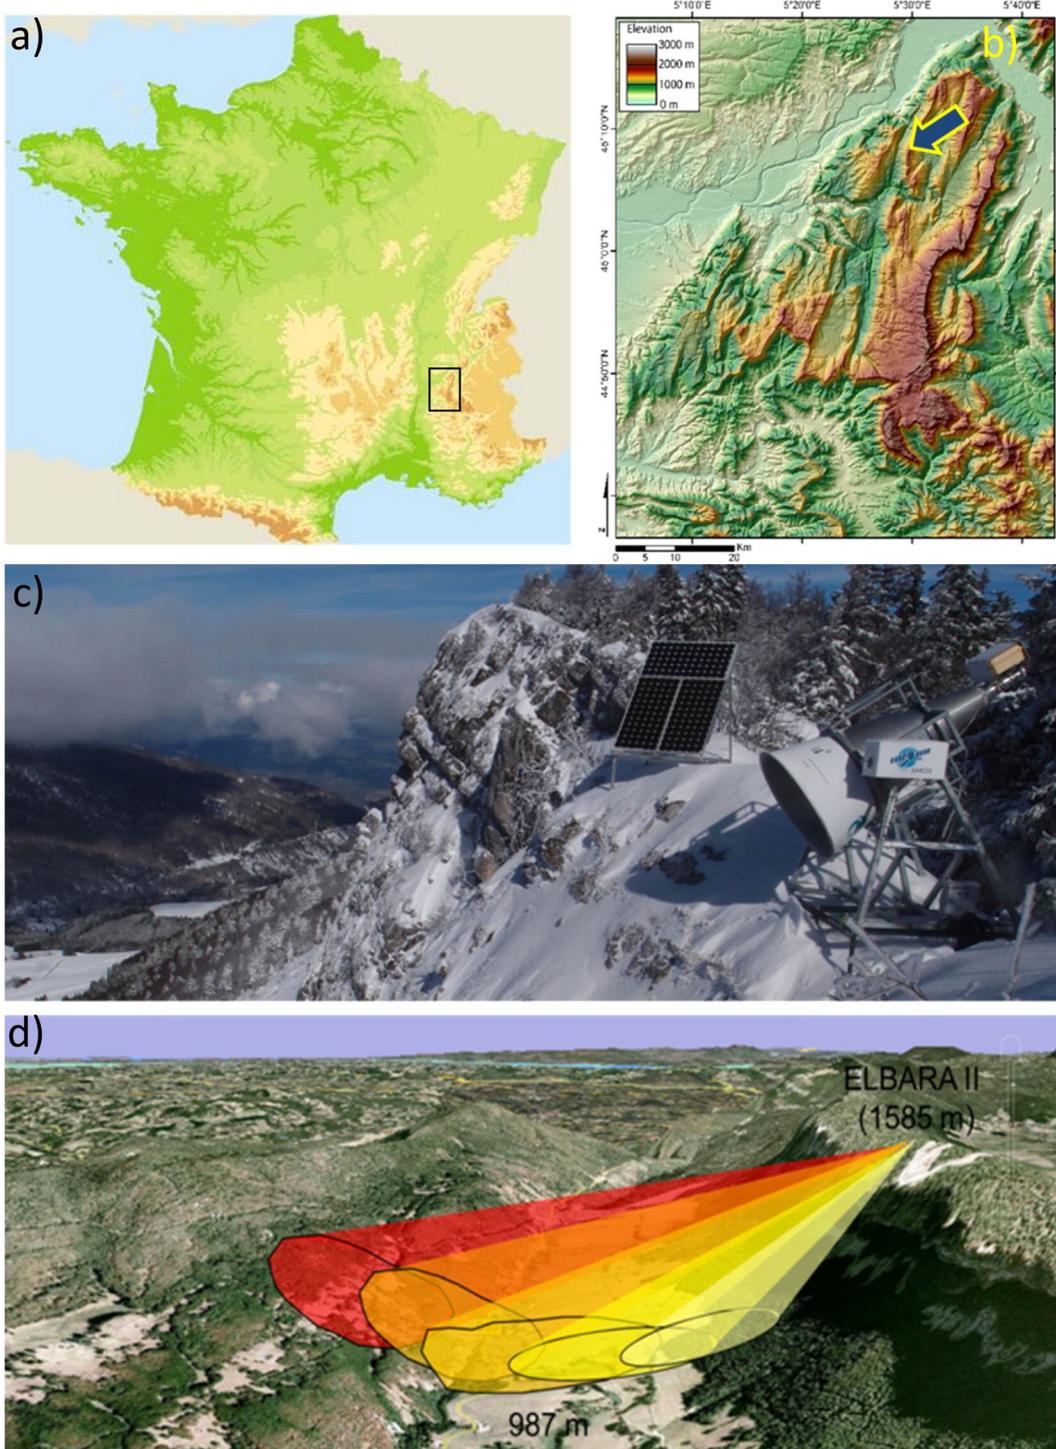
understory) and also by the litter, which intercepts some of the water during rain or snow events.

### 2.2.2. Meteorology

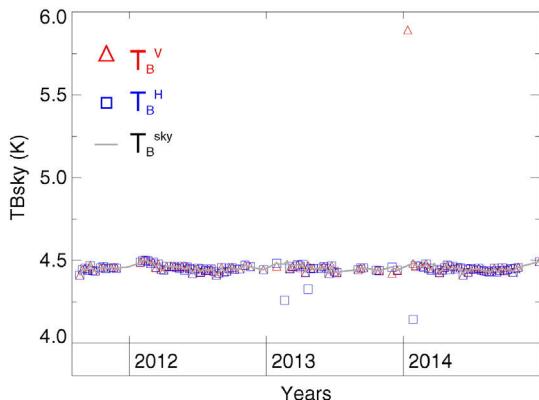
Accumulated precipitation (solid or liquid water) and precipitation intensity were measured by GEONOR T-200B series precipitation gauges (see Fig. 3-c). Other atmospheric variables (air temperature, specific humidity of the air and atmospheric pressure) were monitored with a simple meteorological station and archived on a CR1000 Campbell scientific datalogger located at the Grassland2 site.

### 2.2.3. Vegetation dynamics

The vegetation layer attenuates soil emission and adds its own contribution to the emitted radiation (Wigneron et al., 2007). In this study, we used different *in situ* and satellite products to study the vegetation temporal dynamics. First, we used the MODIS Normalized Difference Vegetation Index (NDVI), which is computed from atmospherically corrected bi-directional surface reflectances masked for water, clouds, heavy aerosols, and cloud shadows (MOD13Q1, 250 m 16 day L3 NDVI product). Second, we collected *in situ* measurements of the vegetation water content (VWC) at various locations within the footprint area



**Fig. 1.** (a) Location of the ELBARA-II radiometer in the French Alps and (b) its location in the Vercors massif. (c) Picture of the radiometer with solar panels and (d) scanning procedure looking toward five footprints (observation angles 55°, 60°, 65°, 70°, 75° from nadir) every 30 min (Google Earth®).



**Fig. 2.** Measured brightness temperatures (horizontal (blue squares) and vertical (red triangles) polarizations) derived from the raw-data measured for the sky-looking radiometer configuration and theoretical TBsky (gray continuous line). (For interpretation of the references to color in this figure legend, the reader is referred to the web version of this article.)

(grassland sites, from April to November 2013). This was done on 30 cm × 30 cm quadrants where the vegetation was entirely cut, weighed, dried in an oven, and weighed again to obtain the VWC in kg/m<sup>2</sup> (fresh and dry weighing method). Finally, we benefited from the SPOT-Take5 experiment (Hagolle et al., 2015). On January 29th, 2013, the orbit of SPOT4 was lowered by 3 km to put it on a 5 day repeat cycle orbit, which made NDVI measurements available every 5 days from February to June 2013 (except when clouds were present) with a 20 m spatial resolution.

#### 2.2.4. Automatic pictures of the target area

In order to check the presence of snow in the target area, pictures were taken automatically every 30 min from the radiometer location (Fig. 5). They were useful to detect harvest dates, to assess the presence of snow or to estimate the areal percentage of the snow cover at the target area.

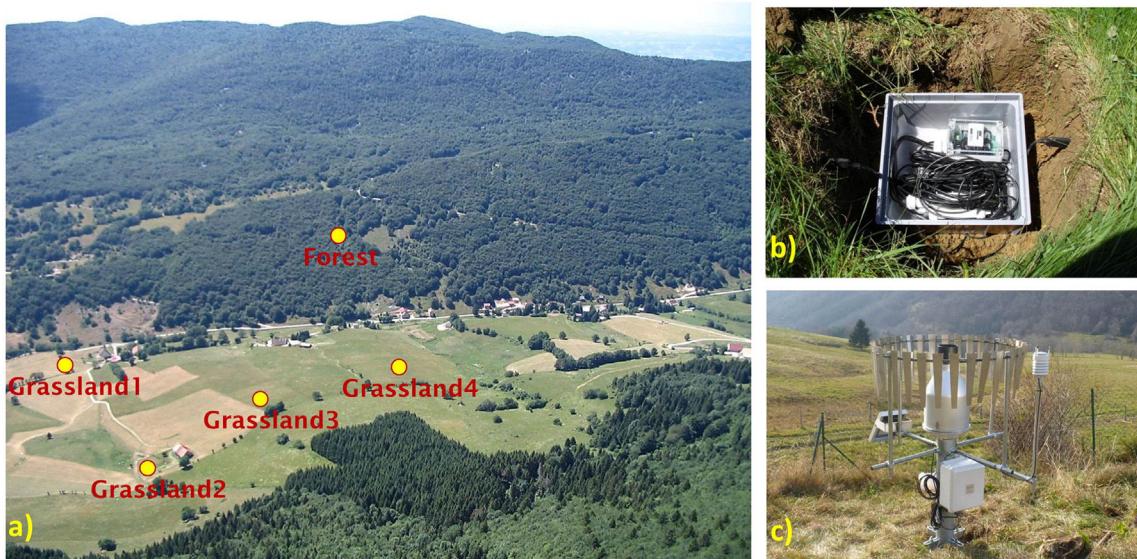
#### 2.3. SAFRAN–Crocus snowpack simulations

The physical properties of snow were not monitored *in situ* during the measurement campaign. Instead, snow properties were simulated

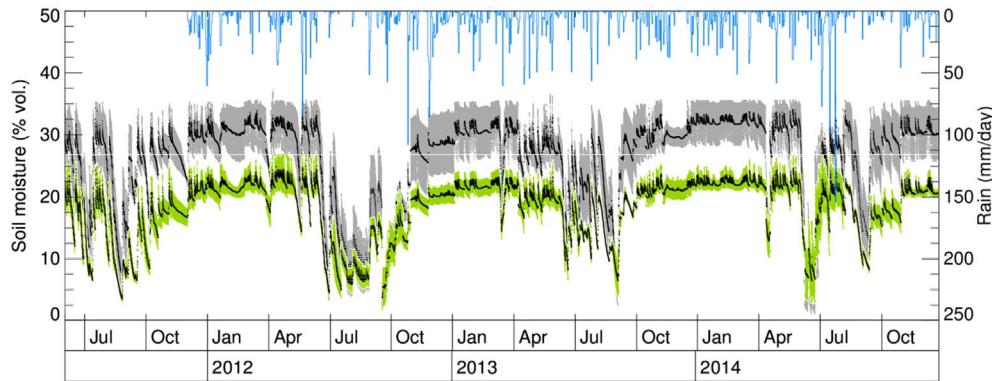
using the Crocus snowpack model coupled to the land surface scheme SURFEX (Vionnet et al., 2012; Masson et al., 2013), fed by the regional reanalysis SAFRAN (Durand et al., 2009). SAFRAN–Crocus (Vionnet et al., 2012) has been used for several decades to analyze and predict the physical state of snow in French mountainous regions. Notwithstanding the large spatial variability of snow properties at all scales, SAFRAN–Crocus is assumed to provide a reasonable representation of the time evolution of the snowpack in the Vercors massif (Lafayesse et al., 2013; Durand et al., 2009).

Crocus is a detailed, multilayer model representing most of the physical processes occurring in snow (surface energy and mass balance, compaction, freeze/thaw and percolation, metamorphism), which is coupled to the multi-layer, land surface model SURFEX. In French mountainous regions, the model is typically driven by the output of the SAFRAN system (Durand et al., 1993). SAFRAN combines the output of large scale meteorological reanalyses with *in situ* snow and meteorological observations, radiosonde data and remotely sensed cloudiness, to provide hourly reanalysis of the meteorological variables needed by Crocus (near surface air temperature, relative humidity, incoming shortwave and longwave radiation, wind speed, snow and rain precipitation). SAFRAN outputs are provided over geographical areas assumed to be meteorologically homogeneous but take the elevation dependence of the meteorological conditions into account. In addition, the model can account for the particular slope and aspect of the simulation conditions. The internal model time step is 15 min, and the output time step is 1 h. In the standard configuration of Crocus, up to 50 layers can be used to represent the vertical profile of snow properties and their time evolution. A constant number of 20 layers are used to represent ground layers down to 10 m. For this study, the temperature of all ground layers of SURFEX was initialized with the SAFRAN mean temperature for the period between 1/8/2001 and 1/8/2014, and a full spin-up was run from 1/8/2001 to 1/8/2011 in order to ensure that near surface ground layers were consistent with the physical setting of the simulation points. The simulation used in this article spanned the period from 1/8/2011 to 31/12/2014.

Of the many variables predicted by SAFRAN–Crocus, total snow depth, snow water equivalent (SWE), bulk snow density, total liquid water content and mean snow temperature were considered to be of particular interest. The bulk density was computed as the ratio between SWE and snow depth. Total liquid water content was computed as the sum of the liquid water contents of the individual layers, and mean snow temperature was computed as the mean of the temperature of all layers, weighted by the mass of each layer.



**Fig. 3.** Illustration of the study area and a soil moisture/temperature station and meteorological station.



**Fig. 4.** Temporal evolution of in situ soil moisture measurements (5 cm depth) over the grassland (8 probes, gray envelope) and forest (2 probes, green envelope) sites, and daily precipitation (since Nov. 2011). (For interpretation of the references to color in this figure legend, the reader is referred to the web version of this article.)

Finally, snow depth comparisons were made over various sites located in the Vercors massif and showed good accuracy of the SAFRAN-Crocus model chain (5 to 10% error on the snow depth for example). In addition, outputs of the model chain were qualitatively assessed using automatic pictures and confirmed the good reliability of the model results for the purposes of our experiment.

In what follows, the model outputs at altitudes 900 m (grassland) and 1200 m (forest) are used, with their orientation (east and west) and slopes of 0° (grassland) and 20° (forest).

### 3. Brightness temperature simulations

The microwave emission from a land surface depends on various spatial and temporal characteristics. In passive microwave, the signal emitted from a land surface (upwelling brightness temperature –  $T_B^p$  at polarization  $p = H, V$ ) is generally written as a function of the ground emissivity ( $e$ ) and the effective soil temperature ( $T_{eff}$ ). At L-band, atmospheric conditions can be ignored as the atmosphere is mostly transparent at the observation wavelength of  $\lambda = 21$  cm ( $f = 1.4$  GHz). On the other hand, the vegetation layer is known to add a non-negligible effect to the soil emission through (i) an attenuation of the signal emitted by the soil (proportional to the density and type of the vegetation cover), (ii) a volume scattering effect within the canopy layer, and (iii) its own contribution to the emitted radiation (Mo, Choudhury, Schmugge, Wang, & Jackson, 1982). Ground emissivity mainly depends on dielectric constant, which is principally determined by the soil moisture content and, to a somewhat smaller extent, by soil density, soil roughness, and textural and structural properties. Finally, although the impact of dry snow cover is known to be weak at L-band, recent studies suggest that even dry snow with mostly negligible absorption can have significant impact on the L-band emission of winter landscapes (Schwank et al., 2014).

#### 3.1. L-MEB model

The L-MEB model (L-band Microwave Emission of the Biosphere) was developed to process the SMOS Level 2 soil moisture product.

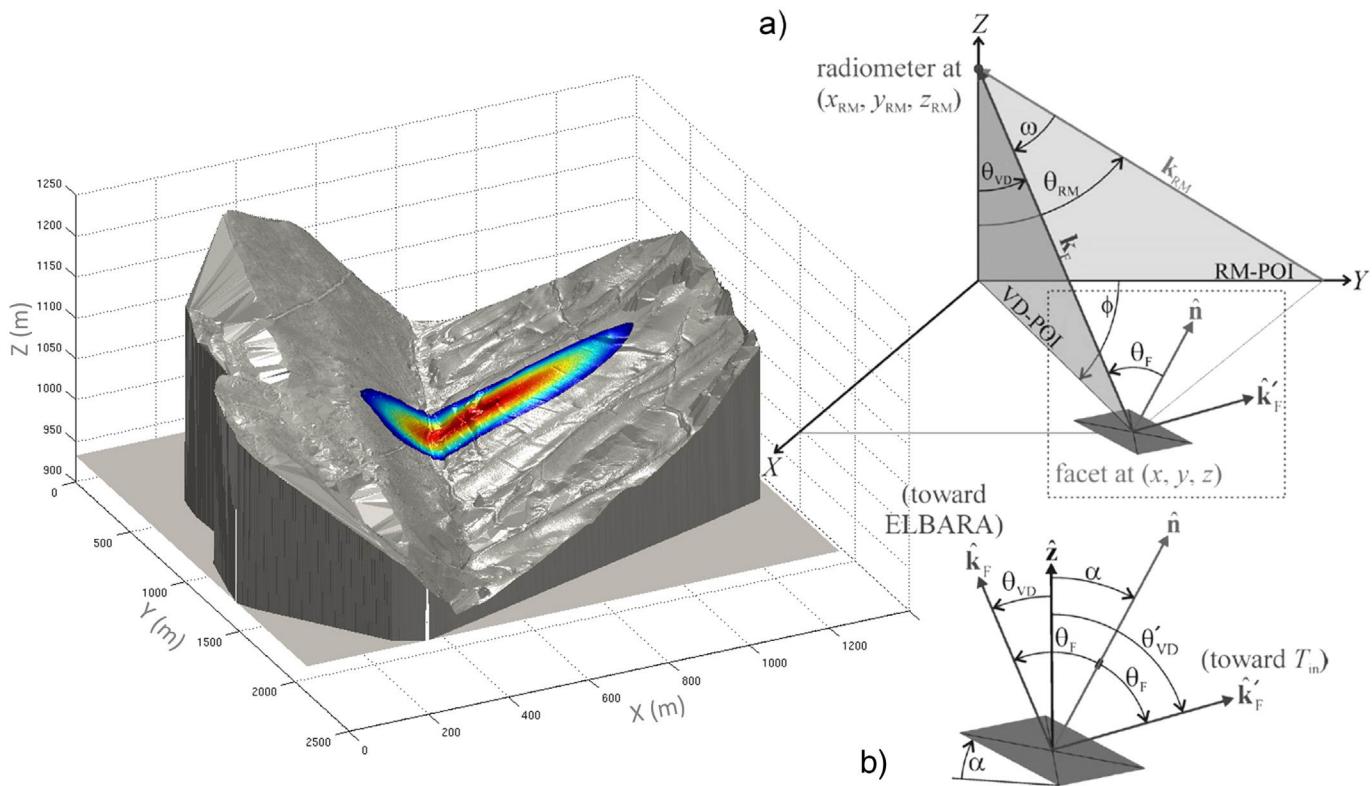
Based on an extensive review of current knowledge of the microwave emission of various land cover types (herbaceous and woody vegetation, frozen and unfrozen bare soil, snow, etc.), the L-MEB model is currently used in forward mode to simultaneously retrieve soil moisture and vegetation optical depth from SMOS  $T_B^p$  measurements in areas without snow cover (Kerr et al., 2010). A detailed description of the L-MEB model can be found in Wigneron et al. (2007). Originally, the L-MEB model included a single dielectric mixing model (Dobson) for the computation of the soil dielectric constant. Recently, Mialon et al. (2015) have evaluated a new model of the soil dielectric constant developed by Mironov, Kerr, Wigneron, Kosolapova, and Demontoux (2013), which has been included in the L-MEB model. Similarly, the vegetation contribution can be modeled using the  $\tau\text{-}\Omega$  approach (Wigneron, Chanzy, Calvet, & Bruguier, 1995) or the Kirdyashev vegetation model (Kirdyashev, Chukhlantsev, & Shutko, 1979). In this paper, we used the Mironov dielectric model and the zero-order  $\tau\text{-}\Omega$  emission model. Finally, the snow contribution was modeled using the HUT (Helsinki University of Technology) snow emission model (Pulliainen, Grandell, & Hallikainen, 1999) in its one-layer configuration.

#### 3.2. Inclusion of the topography

Angles of incidence can play a significant role in passive microwave emission (Utku & Le Vine, 2011; Mialon, Coret, Kerr, Secherre, & Wigneron, 2008; Monerris et al., 2008; Pierdicca, Pulvirenti, & Marzano, 2010). In flat areas, angles of incidence depend only on the angle relative to the vertical direction from the radiometer location. However, in some topographic areas, it is also essential to consider the inclination angle perpendicularly to the radiometer view, which can strongly modify the L-band emission. In that aim, high resolution ( $1 \text{ m}^2$ ) 3D laser scanning of the target area was performed with a lidar system to take the complex topography into account. The lidar was operated from the radiometer location in order to have the same viewing direction toward the footprints as the ELBARA-II instrument. Based on the lidar measurements, we obtained a digitalized elevation model (DEM) of the study area (Fig. 6).



**Fig. 5.** Automatic pictures of the footprint area taken every 30 min (from left to right: Nov. 12 2013 2 pm; Nov. 26 2013 2 pm; Dec. 02 2013 3 pm; Jan. 08 2014 4 pm).



**Fig. 6.** Left, digitalized elevation model (DEM, Romeyeres valley) and calculated location of the 65° footprint ( $-3 \text{ dB}$ , i.e.  $-50\%$  of the energy at the border and  $80\%$  of the footprint energy). The radiometer location is ( $X = 1930 \text{ m}$ ,  $Y = 1090 \text{ m}$ ,  $Z = 1585 \text{ m}$ ). Right, sketch of the geometrical angles required to calculate the microwave emission of each facet ( $1 \text{ m}^2$ ) within the footprint (from Völksch et al., 2015).

From the DEM information and knowing the position of the radiometer, it was possible to accurately define the position of each footprint at the ground level. Fig. 6 presents the  $-3 \text{ dB}$  footprint position on the DEM for the third angle of incidence of the ELBARA-II radiometer ( $65^\circ$ ). Colors represent the percentage of the energy measured by the radiometer according to the directivity pattern of the ELBARA-II antenna, which can be approximated by  $D(\omega) = \exp(-0.01781 \cdot \omega^2)$ , where  $\Omega$  is the angle in degrees with respect to the antenna main direction (Schwank et al., 2010). At the border of the footprint, sensitivity is half the sensitivity ( $-3 \text{ dB}$ ) at the center of the footprint. At the footprint scale, most of the energy (about  $80\%$ ) comes from the  $-3 \text{ dB}$  footprint.

In the L-MEB model, only the angle of incidence  $\theta_F$  is taken into account (see Fig. 6). However, the topography does not act as a simple modification of the angle  $\theta_F$ . A significant effect comes from the angle  $\alpha$ , which describes the tilt of a facet with respect to the horizontal plane and perpendicularly to the radiometer view. When the  $\alpha$  angle increases, the horizontal polarization measurement of the radiometer receives a small contribution from the vertical emission and, similarly, the vertical polarization measurement receives a contribution from the horizontal emission. This results in a mixing of the two polarizations, which can be observed with various satellite passive microwave observations over topographic areas at the global scale (Pellarin, Kerr, & Wigneron, 2006).

To account for this effect, the L-MEB model was modified to handle complex topography within the footprint. A facet model developed during Völksch's PhD thesis (Völksch, 2011), published in Völksch, Schwank, Stähli, and Mätzler (2015) and based on Mätzler and Standley's (2000) work was implemented in the L-MEB model. The location of each  $1 \text{ m}^2$  small planar surface element (facet) is given by its spatial coordinates ( $x, y, z$ ), and the inclination (tilt) and orientation

(exposition) of the facet are described by their surface normal as shown in Fig. 6. In a first step, local reflectivities of the individual facets toward ELBARA-II ( $R_F^H$  and  $R_F^V$ ) were calculated using the L-MEB model. Inputs to the model were the soil moisture, soil temperature, wavelength, polarization, observation angle, soil texture, vegetation water content and, potentially, snow properties.

To calculate overall reflectivities ( $R_{RM}^H$  and  $R_{RM}^V$ ) describing the reflectivity of a given surface facet at horizontal polarization, Völksch proposed the following formula:

$$R_{RM}^H = (\cos^2 \phi \cos^2 \varphi + \sin^2 \phi \cos^2 \theta_{VD} \sin^2 \varphi) R_F^H + (\cos^2 \phi \sin^2 \varphi + \sin^2 \phi \cos^2 \theta_{VD} \cos^2 \varphi) R_F^V. \quad (1)$$

where  $R_F^p$  is the local facet reflectivity at  $p$ -polarization, assuming a flat surface observed from the angle of incidence  $\theta_F$ , and  $\phi$ ,  $\theta_{VD}$  and  $\varphi$  are shown in Fig. 6. It is worth noting that the overall reflectivities  $R_{RM}^H$  at H polarization depend on both H and V polarizations of local facet reflectivities. This is mainly due to the rotation of the plane of linear polarization resulting from the tilt ( $\alpha$ ) of the facets and the deviation of the facet viewing directions from the antenna main axis ( $\phi$ ). In a similar way, the overall reflectivities  $R_{RM}^V$  describing the reflectivity of a considered surface facet at vertical polarization can be calculated as:

$$R_{RM}^V = (\sin^2 \phi \cos^2 \theta_{RM} \cos^2 \varphi + (\sin \theta_{RM} \sin \theta_{VD} + \cos \phi \cos \theta_{RM} \cos \theta_{VD})^2 \sin^2 \varphi) R_F^H + (\sin^2 \phi \cos^2 \theta_{RM} \sin^2 \varphi + (\sin \theta_{RM} \sin \theta_{VD} + \cos \phi \cos \theta_{RM} \cos \theta_{VD})^2 \cos^2 \varphi) R_F^V. \quad (2)$$

Then, the signal emitted by each facet (i.e., the antenna brightness temperature) can be calculated using:

$$T_{B_{RM}}^p = (1 - R_{RM}^p) \cdot T_{eff} + R_{RM}^p \cdot T_{in} \quad (3)$$

where  $T_{eff}$  is the effective physical temperature considered to contribute to the soil emission, which is a combination of deep ( $T_2$ ) and near-surface ( $T_1$ ) temperatures, modified by a factor dependent on the surface soil moisture (SSM), and two calibrated parameters  $w_0$  and  $b_{w0}$  (Wigneron, Laguerre, & Kerr, 2001):

$$T_{eff} = T_2 + (T_1 - T_2) \left( \frac{SSM}{w_0} \right)^{b_{w0}} \quad (4)$$

and  $T_{in}$  is the radiation incident on the facet that is specularly reflected toward ELBARA-II. The  $T_{in}$  radiation is either the sky radiation  $T_{sky} = 5\text{ K} = 2.7\text{ K} + \text{atmospheric contribution}$  (Pellarin et al., 2006) or the radiation coming from the surrounding landscape,  $T_{eff}$  for facets that are obscured from the sky by their surroundings. This point will be discussed in Section 4.2.

Finally, the antenna brightness temperature  $T_{B,\text{tot}}^p$  is the sum of contributions of all facets within the footprint area considered, taking the antenna's directivity pattern into account.

### 3.3. Calibration and TB simulations using the L-MEB model

Brightness temperatures were simulated using the L-MEB model from August 2011 to December 2014. Table 1 presents the variables and parameters required for the L-MEB model. The parameter values presented in Table 1 were either measured at ground level (soil texture) or obtained using the calibration procedure described below (vegetation characteristics, soil roughness, soil effective temperature). The methodology consisted in simulating each TBI at the facet scale ( $1\text{ m}^2$ ), knowing its geometrical characteristics and its soil and vegetation characteristics. A given pixel belonged to one of three kinds of land-cover (grassland, broadleaf forest or coniferous forest). The spatial distribution of the three kinds of land-cover is illustrated in Fig. 7. Then it was assumed that soil and vegetation characteristics were

homogeneous over the three kinds of land-cover, i.e. given by *in situ* soil moisture (5 cm) and soil temperature (10 and 40 cm) measurements recorded in the grassland area or broadleaf forest. The vegetation characteristics are also given in Table 1. Lastly, the brightness temperature at the footprint scale was calculated as the average over all facets TBI, according to the radiation pattern of the ELBARA-II antenna. The calibration procedure consisted in simulating TB footprints for various values of soil ( $w_0$ ;  $b_{w0}$ ;  $H_{soil}$ ;  $Q_{soil}$ ) and vegetation characteristics ( $b_{grassland}$ ,  $\omega_{grassland}$ ,  $b_{forest}$ ,  $\omega_{forest}$ ). To avoid too many simulations, we first exploited the diurnal TB cycle (observed and simulated) in order to fix parameters  $w_0$  and  $b_{w0}$  based on a minimization of the RMSE score. Then, various soil roughness parameters ( $H_{soil}$ ;  $Q_{soil}$ ) were tested and fixed at 0.1 and 0.2 respectively using the same minimization method. For the vegetation parameter, we concentrated on the forest footprint ( $75^\circ$ ) to determine the  $b_{forest}$  and  $\omega_{forest}$  parameters while the grassland footprint ( $60^\circ$ ) was used to determine the  $b_{grassland}$  and  $\omega_{grassland}$  parameters. Finally, mixed footprints ( $55^\circ$ ,  $65^\circ$  and  $70^\circ$ ) were used to check and slightly modify (if necessary) the chosen parameters.

## 4. Results

Fig. 8 presents the ELBARA-II brightness temperatures  $T_B^p$  ( $p = H, V$ ) measured at two different angles of incidence ( $55^\circ$  and  $75^\circ$ ) at horizontal ( $p = H$ , blue) and vertical ( $p = V$ , red) polarizations. The footprint area related to the  $55^\circ$  incidence angle was predominantly composed of grassland (62%) and coniferous forest (38%) whereas the footprint area related to the  $75^\circ$  incidence angle was mostly composed of broadleaf forest (79%). Gray dots represent measurements suspected of internal or external distortions, which were eliminated. Both graphs illustrate the seasonal variation of brightness temperature measurements  $T_B^p$  ( $p = H, V$ ) with higher  $T_B^p$  in summer and lower  $T_B^p$  in winter. In addition, the long- and short-term dynamics of  $T_B^p$  was significantly higher over the grassland footprint (about 40 K at polarization  $p = H$ ) whereas the dynamics was weaker (about 20 K) over the forest footprint. This well-known behavior was due to the variation of vegetation optical depth, which was found to be closely related to the vegetation water content for crops and to the total branch water content for forests (Ferrazzoli, Guerriero, & Wigneron, 2002). Also shown in Fig. 8 is the snow depth derived from SAFRAN-Crocus simulations. This point will be discussed in Section 4.5.

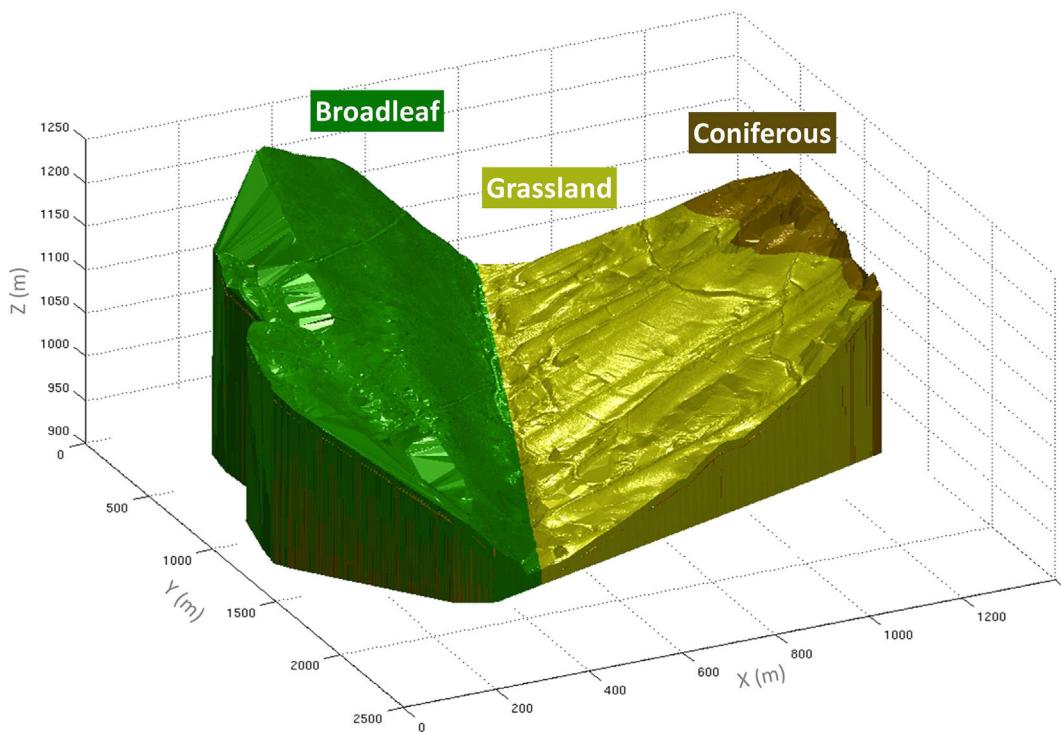
### 4.1. Impact of the topography

In topographic areas, angles of incidence in the target area could not be derived solely from the radiometer observation angle. Based on the DEM and the radiometer location, it was possible to calculate the local angles of incidence ( $\theta_F$ , cf. Fig. 6). Fig. 9 shows the distribution of these local angles  $\theta_F$  within five radiometer footprints ( $55^\circ$ ,  $60^\circ$ ,  $65^\circ$ ,  $70^\circ$  and  $75^\circ$ ). The mean local angles of incidence in these five footprints were  $71.7^\circ$ ,  $71.3^\circ$ ,  $66.1^\circ$ ,  $60.1^\circ$  and  $59.4^\circ$  respectively. In addition to these angles of incidence, the inclinations of the facets with respect to the horizontal plane and perpendicularly to the radiometer line of view (tilt,  $\alpha$ , see Fig. 6) were also computed and tended to mix the two polarizations. To illustrate this behavior, the L-MEB model was used to simulate brightness temperature for all local facets within a radiometer footprint. Fig. 10 was obtained for the  $65^\circ$  radiometer footprint using a uniform soil moisture value for all facets ( $0.35\text{ m}^3/\text{m}^3$ ). These two graphs show that the presence of topography generates a mixing of the two polarizations. Without inclination angles ( $\alpha$ ), brightness temperatures follow the well-known relationship between  $T_B^p$  and angle of incidence indicated by the two black curves in Fig. 10. The difference between the two  $T_B$  polarizations (with or without accounting for inclination angles) could reach 30 K. Nevertheless, at the footprint scale, the difference between  $T_B^p$  whether Eqs. (1) and (2) were taken into account or not was quite small (1 K in V-pol and 2 K in H-pol). This was due to the configuration of the experiment, where the radiometer viewing direction was

**Table 1**

Main input variables and parameters of the L-Band Microwave Emission of Biosphere (L-MEB) Model. The parameter values (lower part of the table) were obtained with a calibration procedure.

Symbol	Definition	Value/unit	Origin
<i>Variables</i>			
$T_1$	Surface temperature (10 cm)	K	<i>In situ</i>
$T_2$	Soil temperature (50 cm)	K	<i>In situ</i>
$SSM$	Surface soil moisture	$\text{m}^3 \cdot \text{m}^{-3}$	<i>In situ</i>
$HS$	Snow depth	m	SAFRAN–Crocus
$\rho_{snow}$	Bulk snow density	$\text{kg m}^{-3}$	SAFRAN–Crocus
$LWC_{snow}$	Liquid water content of the snow pack	$\text{kg m}^{-2}$	SAFRAN–Crocus
$T_{snow}$	Snow temperature	K	SAFRAN–Crocus
$VWc$	Vegetation water content	$\text{kg/m}^2$	$f(\text{NDVI-MODIS})$
	-Grassland	$2.5 \times \text{NDVI} + f(\text{Spot-Take5})$	
	-Coniferous	0.05	<i>In situ</i>
	-Broadleaf	$3 \text{ kg/m}^2$	
		$4 \text{ kg/m}^2$	
<i>Parameters (soil and vegetation)</i>			
$\omega_{grassland}$ ; $\omega_{forest}$	Vegetation L-band single scattering albedo	0.10; 0.10	Calibration
$b_{grassland}$ ; $b_{forest}$	Ratio $\tau/VWc$	$0.15/0.15\text{ m}^2$	Calibration
$w_0$ ; $b_{w0}$	Effective temperature parameters	$0.5 \text{ m}^3 \text{ m}^{-3}$ ; 0.8 [-]	Calibration
$Clay$ ; $Sand$	Soil texture	30.8%; 36.8%	<i>In-situ</i>
$h_{soil}$ ; $q_{soil}$ ; $n_{soil}$	Soil effective roughness parameters	0.1; 0.2; 0	Calibration



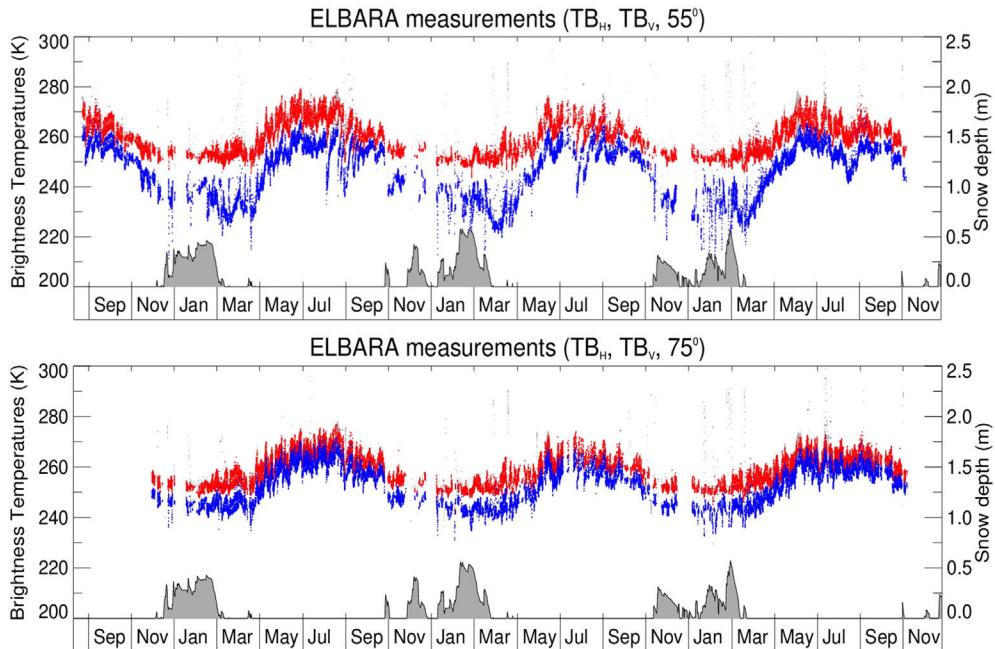
**Fig. 7.** Spatial distribution of the three kinds of land cover.

the same for the two slopes, which led to rather small inclination angles,  $\alpha$ , ranging between  $-1.8^\circ$  and  $0.9^\circ$ .

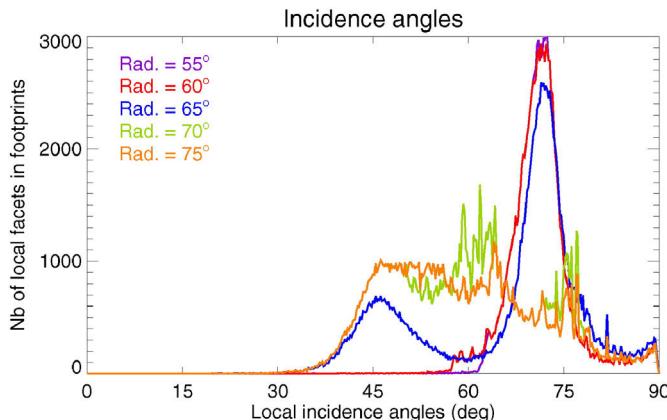
#### 4.2. Impact of the surrounding reflection

As discussed in Section 3.2, a small portion of the signal ( $R_{RM}^p T_{in}$  in eq. 3) usually comes from the sky radiation reflected in the radiometer direction by the ground. This quantity is the contribution of both the galactic emission (2.7 K) and the atmosphere (more or less 1.5 K at L-band, Pellarin et al., 2006). However, in the ELBARA-II configuration on the

experimental site of this study, the “sky” reflection could potentially come from the surrounding landscape, particularly from the opposite slope. In this case, the  $T_{in}$  value in eq. 3 (about 4.5 K, see Fig. 2) should be replaced by the radiation coming from the surrounding landscape, which was generally between 180 K and 250 K in H-pol and between 250 K and 280 K in V-pol (cf. Fig. 10). The DEM was used to identify facets affected by the surrounding reflection. The result showed that 84% of facets located on the radiometer side of the slope (i.e. right slope in Fig. 11) were affected. An illustration of the impact on brightness temperature simulation is given in Fig. 11. The left graph shows



**Fig. 8.** ELBARA-II measured brightness temperatures (H-pol in blue and V-pol in red) for two incidence angles ( $55$  and  $75^\circ$ ) from August 2011 to November 2014. Snow depth derived from SAFRAN-CROCUS simulations is also presented. (For interpretation of the references to color in this figure legend, the reader is referred to the web version of this article.)



**Fig. 9.** Local facet incidence angles within the 3 radiometer footprints ( $60^{\circ}$ ,  $65^{\circ}$  and  $70^{\circ}$ ). Y-axis is a number of facets.

local facets TBH assuming that  $T_{in}$  comes from the sky, and the right graph presents local TBH taking the surrounding reflection into account. In this example, the difference between the TBp of the two footprints is 31 K and 12 K in horizontal and vertical polarization respectively (for the  $65^{\circ}$  ELBARA-II footprint). This behavior is taken into account in the following.

#### 4.3. Vegetation water content

Vegetation plays a significant role in the land surface emission at L-band. In the L-MEB model, the vegetation contribution is modeled using the zero-order  $\tau - \Omega$  approach. This model is based on two parameters, the optical depth  $\tau_p$  and the single scattering albedo  $\Omega_p$ , which are used to parameterize the vegetation attenuation properties and the scattering effects within the canopy layer, respectively (Mo et al., 1982). The optical depth  $\tau_p$  is sensitive to the vegetation water content ( $\text{kg/m}^2$ ) and to a structure parameter (b-factor) depending on the vegetation as:  $\tau = b \times \text{VWC}$  (Jackson & Schmugge, 1991; Van de Griend & Wigneron, 2004). For coniferous and broadleaf forest, VWC is assumed to be constant in time and equal to 3 and  $4 \text{ kg/m}^2$  respectively (Pellarin, Calvet, & Wigneron, 2003). In contrast, for crop and grassland land covers, the VWC is generally assumed to be linearly related to the LAI (Leaf Area Index) or NDVI (Saleh et al., 2007).

As specified in Section 2.2.3, we used various approaches to derive VWC observations. First, we compared *in situ* VWC measurements (obtained over  $30 \text{ cm} \times 30 \text{ cm}$  quadrants in various locations) with the MODIS 250 m L3 NDVI product. A temporal shift of 1.5 months was observed between NDVI increase (in March–April) and VWC increase (in

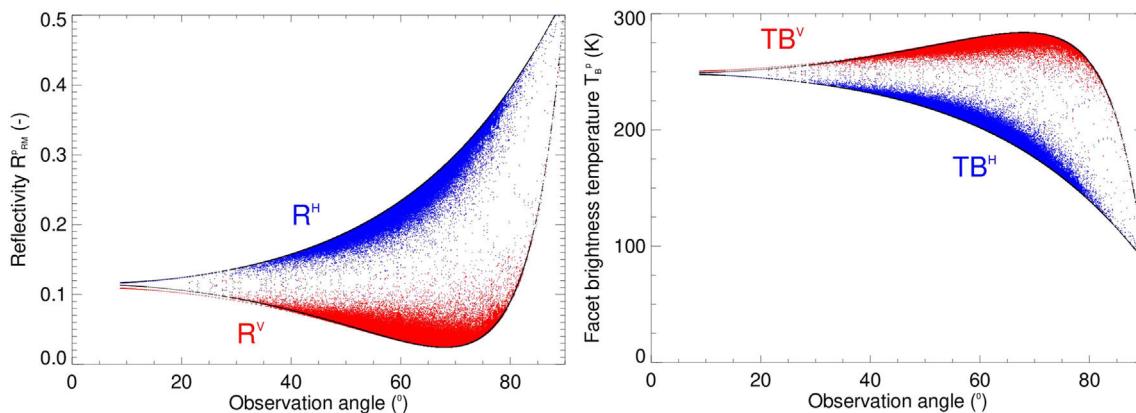
April–May). To understand this, we took advantage of the high resolution NDVI product provided by the SPOT-Take5 experiment (from February to June 2013). Fig. 12 shows a comparison of the three products (two different NDVI products and *in situ* VWC measurements). Error bars related to VWC measurements describe the minimum and maximum values of VWC obtained over three  $30 \text{ cm} \times 30 \text{ cm}$  quadrants for each of the eight measurement dates. It can be noted that the SPOT-Take5 dynamics is in agreement with the *in situ* VWC measurements. The dashed curve is an interpolation of the VWC measurements.

#### 4.4. L-MEB simulations versus ELBARA TB measurements

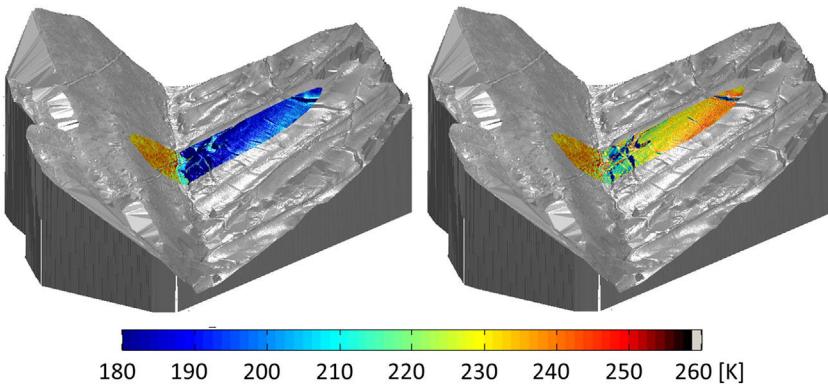
A first simulation was made with the MODIS 250 m L3 NDVI product and the results are reported in Fig. 13-b. As discussed in Section 3.3, a calibration procedure based on minimizing the RMSE between ELBARA-II  $T_B^p$  ( $p = H, V$ ) measurements and L-MEB TB simulation was used to estimate both the vegetation parameters ( $b$  and  $\Omega$  for forest and grassland vegetation types respectively) and the evolution of VWC based on MODIS-NDVI product. The best result was obtained with grassland  $\text{VWC} [\text{kg/m}^2] = 2.5 \times \text{NDVI-MODIS} + 0.05$  and is plotted in Fig. 13-b (grassland: lower dashed line, forest: upper dashed line). Note that periods with snow cover were removed from the  $R^2$  and the RMSE score presented in the scatterplots. During these periods,  $T_B^p$  are plotted in gray in the scatterplot. Major discrepancies relative to ELBARA-II measurements (Fig. 13-a), occur during spring, when the early grassland vegetation growth (lower black dashed curve in Fig. 13-b) leads to incorrect  $T_B^p$  simulations, particularly in H-polarization. Similarly, during fall, the decrease of simulated  $T_B^H$  due to the grassland senescence is in advance compared to  $T_B^V$  measurements.

A second simulation was run using the VWC projection derived from *in situ* measurements and presented in Fig. 12 (black dashed curve). The results are presented in Fig. 13-c. Good overall agreement can be observed during spring, when the simulated  $T_B^H$  are close to the observed  $T_B^H$ . On the other hand, the fall is still not in agreement with ELBARA-II measurements.

Thus, two other factors were assumed to be potentially responsible for this behavior. The first was related to a potential evolution of the soil roughness parameter ( $h_{\text{soil}}$ ) but the sensitivity analysis conducted led to high, and unrealistic, values of the  $h_{\text{soil}}$  parameter in fall. The second hypothesis was related to an evolution of the structural parameter of the grassland vegetation ( $b_{\text{grassland}}$ ). This suggested an evolution of the grassland vegetation structure from spring to autumn. Ground observation showed standing grassland vegetation from April to June and slanting vegetation in autumn, which could be responsible for an evolution of the  $b_{\text{grassland}}$  parameter as demonstrated by Schwank, Mätzler, Guglielmetti, and Flühler (2005). In a last simulation, the



**Fig. 10.** Reflectivity and brightness temperature simulation for all individual facets seen from the radiometer location ( $65^{\circ}$  footprint). Without taking into account facet inclination, individual TBs should follow the two black lines corresponding to  $R_F^H$ ,  $R_F^V$  and  $TB_F^H$  and  $TB_F^V$  respectively.



**Fig. 11.** H-pol brightness temperature simulation (K) of all individual facets within the 65° footprint (a) assuming that  $T_{in}$  comes from the sky and (b) accounting for facets affected with surrounding reflection. In this example, the overall contribution is 31 K in H-pol and 12 K in V-pol.

$b_{grassland}$  parameter was changed from 0.15 to 0.25 in September–October and November. The value of 0.25 was simply calibrated to match observed and simulated TB during this period. The results are presented in Fig. 13-d and show relatively good agreement with ELBARA-II measurements ( $R^2 = 0.84$  and RMSE = 5.4 K).

To sum up, the last simulation (Fig. 13-d) was run using the following soil and vegetation parameters:  $w_0 = 0.5 \text{ m}^3 \cdot \text{m}^{-3}$ ;  $b_{w0} = 0.8$ ;  $H_{soil} = 0.1$ ;  $Q_{soil} = 0.2$ ;  $n_{soil} = 0$ ; Clay = 30.8%, Sand = 36.8%;  $b_{grassland} = 0.15$  or 0.25 (Sept–Nov),  $\omega_{grassland} = 0.10$ ;  $b_{forest} = 0.15$ ,  $\omega_{forest} = 0.10$  (see Table 1). The corresponding statistical scores are presented in Table 2.

Similarly, simulations were run over the other four footprints (55, 60, 70 and 75°) using the same soil and vegetation parameters, and the statistical scores are presented in Table 2. To avoid too many graphs, we decided to present L-MEB TB simulations corresponding to the 55° and 75° radiometer angles of incidence (Fig. 14), for comparison with the TB measurements presented in Fig. 8. The radiometer footprint at 55° observation angle is composed of 38% of coniferous forest ( $VWc = 3 \text{ kg/m}^2$ ) and 62% of grassland ( $VWc$  value between 0.2 and 2.2  $\text{kg/m}^2$ ). Local angles of incidence within the footprint are almost grazing (60° to 80°). Statistical scores are slightly better than at 65°;  $R^2 = 0.83$ , RMS = 4.4 K and bias = −0.3 K. On the other hand, the radiometer footprint at 75° observation angle is composed of 79% broadleaf forest ( $VWc = 4 \text{ kg/m}^2$ ) and 21% grassland. Since the radiometer footprint at 75° observation angle is mainly located on the slope opposite the radiometer, many local angles of incidence range from 30° to 65°. These smaller local angles automatically increase the mean  $T_B^H$  values as illustrated in Fig. 10 but generate only a small effect on  $T_B^V$

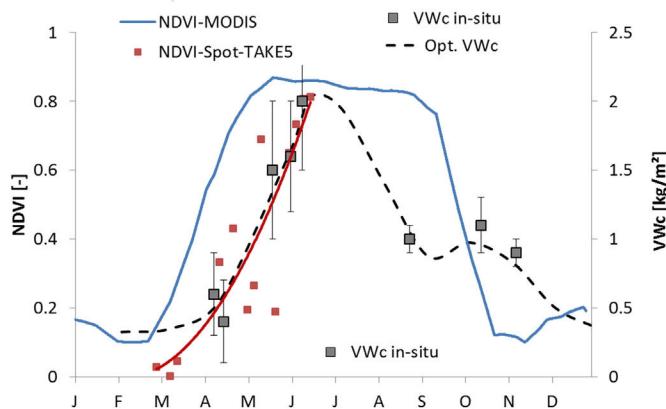
values. On the other hand, the presence of 79% of forest leads to a reduction in the difference between the two polarizations. Statistical scores are weaker in terms of correlation ( $R^2 = 0.61$ ) but the RMS and bias values are better (5.0 K and 0.8 K respectively). Similar statistical scores can be observed (Table 2) on the two radiometer footprints (60 and 70°).

#### 4.5. Wet and dry snow

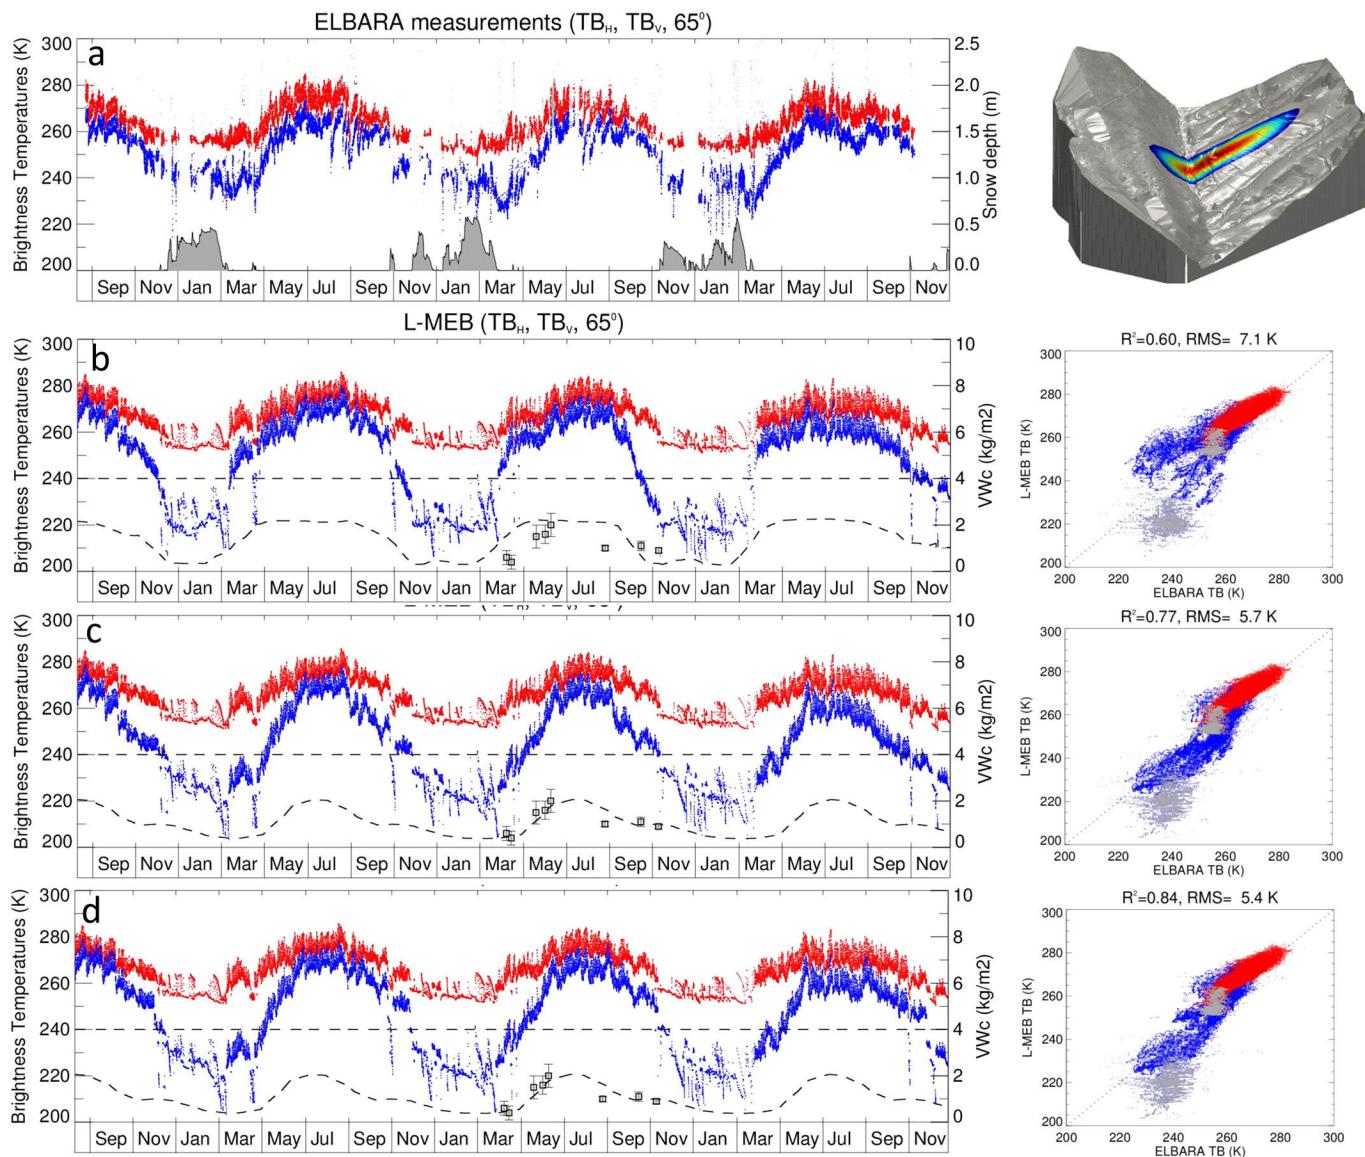
The altitude of the footprint area ranges from 950 to 1350 m above sea level. Consequently, snow occurs approximately from December to April each year as illustrated in Figs. 5 and 8. Snow depth and snow liquid water content (LWC) extracted from the SAFRAN-Crocus simulation over the grassland site (1200 m) are shown as an example in Fig. 15 for a 2-month period (February and March 2012). Early February was particularly cold in Western Europe that year and 2-m air temperature measurements recorded at the meteorological station were negative from January 27th to February 16th, reaching a minimum on February 5th (9:30 UTC) of  $-19.8^\circ\text{C}$ . During this period, the simulated snow depth was stable (about 50 cm) and totally dry as shown in Fig. 15. Corresponding ELBARA-II  $T_B^H$  were also quite constant with  $T_B^H \approx 260 \text{ K} \pm 2 \text{ K}$  and  $T_B^V \approx 240 \text{ K} \pm 3 \text{ K}$  which is quite similar to the results obtained by Rautiainen et al. (2012) in Finland under dry snow pack conditions.

From February 16th, 2-m air temperature returned to positive values and SAFRAN-Crocus results indicated a partial melting of the snow pack at the surface (0–10 cm) in the afternoons (see Fig. 15). The snow liquid water content was observed to have a strong impact on ELBARA-II  $T_B^H$  measurements, particularly at horizontal polarization, which decreased significantly, by about 20 K compared to the previous days. Similar behavior of  $T_B^H$  at horizontal polarization in snow melting conditions has been observed by Rautiainen et al. (2012) in Boreal regions. This behavior is different from that at higher frequency bands. Usually, passive microwaves are known to saturate (i.e. increase) when snow liquid water occurs in the surface snow-pack. For instance, this was observed in Antarctica with SSM/I satellite sensors (18–19 GHz) by Ridley (1993) and Picard and Fily (2006), or in Greenland by Abdalati and Steffen (1997). In contrast, at lower frequencies (4.9 GHz), Hofer and Good (1979) and Hofer and Mätzler (1980) observed a strong decrease of the TB H-pol measurements for an increase of the snow LWC from 0 to 2% by volume. This behavior seems to be similar at 1.4 GHz. An explanation for this is that the reflectivity increases with increasing LWC at low frequencies (1–5 GHz), whereas for a wet surface, the snow-pack is almost a black body at higher frequencies (18–90 GHz, Hofer & Mätzler, 1980).

Fig. 15 shows various  $T_B^H$  behaviors during the 2-month period. First, two periods similar to early February can be identified: March 5–7th and March 18–19th. During these two periods, 2-m air temperature measurements fell below  $0^\circ\text{C}$  and  $T_B^H$  increased by 20 K, becoming



**Fig. 12.** Temporal evolution of various vegetation products on the grassland site (2013). The vegetation growth is not observed at the same date using MODIS-250m (March–April) or SPOT-Take5-20m and in-situ  $VWc$  measurements (April–May).



**Fig. 13.** Measured (a) and simulated TBp (b, c, d) after calibration of  $w_0$ ,  $bw_0$ ,  $b$ ,  $\omega$ ,  $H_{soil}$  and  $Q_{soil}$  parameters. Vertical (red plots) and horizontal (blue plots). Simulations were performed using (b) MODIS-derived VWC ( $VWC = 2.5NDVI + 0.05$ ), (c) *in situ* derived VWC and (d) same as (c) with a modification of the  $b_{grassland}$  parameter in autumn. Dashed lines correspond to the VWC for the grassland landcover and the forest landcover ( $4 \text{ kg/m}^2$ ). Squares correspond to VWC *in situ* measurements. (For interpretation of the references to color in this figure legend, the reader is referred to the web version of this article.)

quite stable. Along with low air temperature on March 5–7th, the simulated snow depth remained stable and the surface snow layer (0–10 cm) was completely refrozen at night. Similarly, a small snow event occurred on March 18th (confirmed by automatic pictures taken from the radiometer location) and led to similar  $T_B^H$  behavior. Note that soil temperature monitored at 10 and 40 cm during the entire 2-month period never fell below 0 °C. During snow melting periods

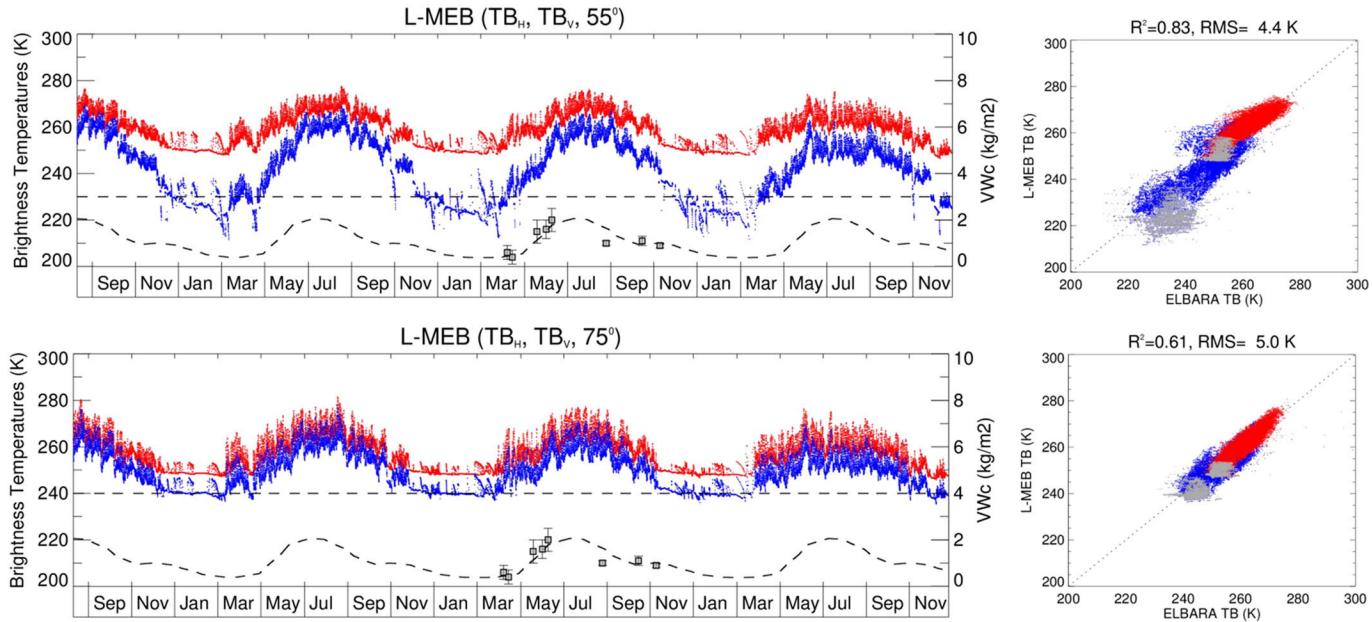
(mainly from February 22nd to March 4th),  $T_B^H$  values in the afternoon were always lower than in the morning. Fig. 15 distinguishes morning (06:00) from afternoon (18:00)  $T_B^H$  by using open and filled symbols. Usually, a typical daily evolution of brightness temperature measurement shows a minimal value of  $T_B^H$  at the end of the night (06:00) and a maximum value in the afternoon (16:00 to 18:00). This can be observed when no snow is present, from March 14th onwards, with the exception of a short cold period on March 18–19th. Conversely, during snow melting periods, a minimal value of  $T_B^H$  can be observed in the afternoon.

The snow melting signature at L-band can potentially be useful for the SMOS (or SMAP) mission to detect snow melting areas since ascending and descending orbits are frequently available on the same day, particularly at high latitudes. Fig. 16 illustrates this potential application, focusing on two periods in 2013: November 28–29th (left graph) and a few days later, December 3–4th (right graph). Snow cover (25 cm) is present during both periods (confirmed by automatic pictures and SAFRAN-Crocus model) but the ELBARA-II  $T_B^H$  signature is quite different from the first period to the second. During the first

**Table 2**

Statistical scores associated with TB (H, V and both) simulations shown on Fig. 13d (65°) and for the four other incidence angles (55, 60, 70 and 75°).

Obs. angle (deg)	$R^2$			RMSE (K)			Bias (K)		
	TBV	TBH	TB	TBV	TBH	TB	TBV	TBH	TB
55°	0.78	0.71	0.83	3.1	5.4	4.4	-1.5	0.9	-0.3
60°	0.79	0.75	0.84	3.3	6.0	4.8	-0.1	0.1	0.0
65°	0.81	0.78	0.84	4.5	6.2	5.4	-3.6	-0.6	-2.1
70°	0.77	0.74	0.81	3.1	4.2	3.7	-1.4	-0.1	-0.7
75°	0.45	0.62	0.61	5.4	4.6	5.0	0.2	1.3	0.8



**Fig. 14.** same as Fig. 13d but for incidence angles 55 and 75°. Scatterplots present the comparisons with corresponding ELBARA TB measurements (55 and 75°) shown in Fig. 8.

period, 2-m air temperature is below 0 °C and the snow pack is dry; the corresponding  $T_B^H$  shows the usual daily evolution (max in the afternoon). However, 2-m air temperature is positive during the second period. The snow pack is melting and a strong decrease of the  $T_B^H$  can be easily observed in the afternoon. Note that soil temperature measurements (10 cm depth) recorded during this period (and reported in Fig. 16) indicate that the soil was not frozen at 10 cm depth (+2.3 °C for the two periods). Theoretically, by considering two successive SMOS TB measurements at 06:00 and 18:00 (SMOS overpass symbolized with circles in Fig. 16), it should be possible to detect areas undergoing daily snow freeze/thaw cycles. Further investigations are needed to develop this last point.

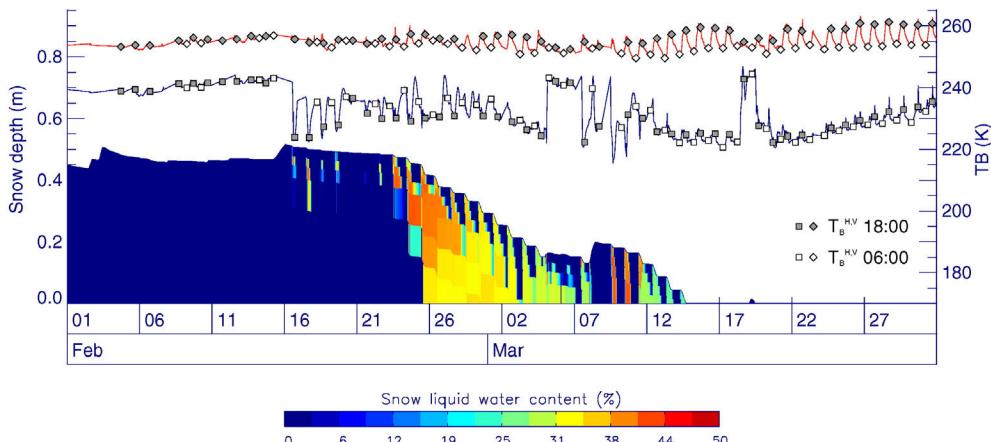
## 5. Conclusions

This paper presents three years of passive L-band measurements obtained in a mountainous region from an ESA radiometer (ELBARA-II) installed on top of a steep mountain. The originality of this experiment is that the radiometer was located at a considerable distance from the target area, which led to relatively large footprints at ground level,

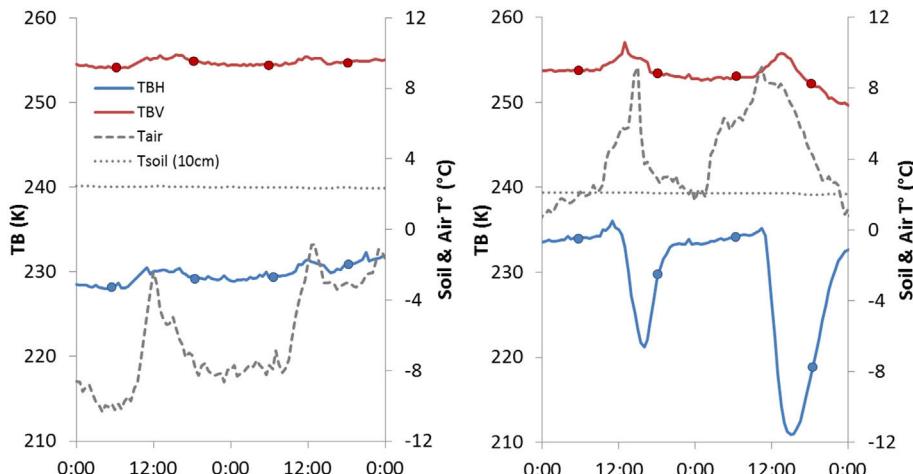
ranging from 120,800 m<sup>2</sup> to 166,000 m<sup>2</sup> (at 3 dB) depending on the angle of incidence.

First, the complex topography of the studied area was based on a digitalized elevation model (1 m<sup>2</sup>) obtained using Lidar measurements. It was shown that the topography generated a mixing of the horizontal and vertical polarizations due to inclination angles, i.e. facet angles perpendicular to the radiometer view direction. It was also found that a significant part of the signal measured by the radiometer came from reflection from the slope opposite to the radiometer. The overall contribution was found to be equal to 31 K in H-pol and 12 K in V-pol. Taking the inclination angles and the potential reflection from surrounding topography into account might have an impact at the SMOS/SMAP spatial scale and should be further investigated to improve soil moisture retrievals over topographic areas. In a previous study, Pellarin et al. (2006) showed that the influence of topography was found to increase from X-band to C-band, and was expected to be more significant at L-band.

Second, the MODIS-250 m NDVI product, used in initial L-MEB simulations, was found to be inadequate to represent the seasonal evolution of ELBARA-II measurements. The use of *in situ* measurements,



**Fig. 15.** Evolution of snow depth and liquid water content during February–March 2012. The ELBARA-II (65° footprint) measured TBH (blue) and TBV (red) are also indicated on right axis. Open and filled-in symbols illustrate TBP measured in the morning (06:00) or in the afternoon (18:00) corresponding to SMOS overpass time. (For interpretation of the references to color in this figure legend, the reader is referred to the web version of this article.)



**Fig. 16.** ELBARA-II 60° TBp ( $p = H$  (blue) and  $p = V$  (red)) during two periods in 2013 with 25 cm snow depth at the ground level (November 28–29th (left graph) and December 3–4th (right graph)). The strong signature at H-pol during the second period indicates the presence of liquid water content in the snow pack which is supported by 2-m air temperature measurements (dashed line). This signature might be observed at the SMOS scale using two successive SMOS overpasses at 6 am and 6 pm (symbolized with circles). (For interpretation of the references to color in this figure legend, the reader is referred to the web version of this article.)

consistent with the SPOT-Take5–20m NDVI product, strongly improved the L-MEB simulation, mainly during the spring. Finally, it was not possible to reproduce the vegetation signal measured at the end of each year (October–November) with the L-MEB model without assuming a temporal evolution of the b-factor parameter. This could be due to a change in the grassland structure (standing vegetation in spring and summer and slanting vegetation in fall). In the SMOS retrieval algorithm, the MODIS LAI product was only used to initialize the value of the vegetation optical depth (which was estimated together with soil moisture). It was thus expected that the uncertainties on the LAI (or NDVI) values would have a relatively low impact on the soil moisture retrievals (Wigneron et al., 2007). In contrast, the effect of vegetation structure on vegetation optical depth was found to be significant in several studies and might play a role in soil moisture retrieval quality. Further studies are needed to develop this point.

Third, an interesting signature was found under snow conditions. Dry snow conditions were found to have non-negligible impact at L-band, mostly for the horizontal polarization. It was shown that a short snow event could cause a strong increase of  $T_B^H$  by about 20 K. Soil temperature sensors at 10 cm depth ruled out the possibility of a frozen soil effect. Conversely, in snow melting conditions,  $T_B^H$  were found to decrease by about 20 K in the afternoon. No clear signal could be observed in vertical polarization. A potential application with SMOS or SMAP passive microwave measurements using two successive SMOS/SMAP orbits at 06:00 and 18:00 might be proposed to detect areas where snow undergoes daily freeze–thaw cycles.

## Acknowledgments

This study received financial support from TOSCA (CNES, Centre National d'Etudes Spatiales, France) and ESA (European Space Agency) for the loan of the ELBARA-II radiometer (ESTEC ELBARA-II Loan Agreement 21013/07/NL/FF). Particular thanks go to Simon Gascoin from CESBIO for providing us with SPOT Take5 NDVI measurements over the Vercors site. LTRE and CNRM-GAME/CEN are part of LabEx OSUG@2020 (ANR10 LABX56).

## References

- Abdalati, W., & Steffen, K. (1997). Snowmelt on the Greenland ice sheet as derived from passive microwave satellite data. *Journal of Climate*, *10*, 165–175.
- Albergel, C., Zakharova, E., Calvet, J. C., Zribi, M., Parde, M., Wigneron, J. P., ... Fritz, N. E. D. (2011). A first assessment of the SMOS data in southwestern France using *in situ* and airborne soil moisture estimates: The CAROLS airborne campaign. *Remote Sensing of Environment*, *115*, 2718–2728.
- Bircher, S., Skou, N., Jensen, K. H., Walker, J. P., & Rasmussen, L. (2012). A soil moisture and temperature network for SMOS validation in Western Denmark. *Hydrology and Earth System Sciences*, *16*, 1445–1463.
- Bircher, S., Skou, N., & Kerr, Y. H. (2013). Validation of SMOS L1C and L2 products and important parameters of the retrieval algorithm in the Skjern River Catchment, Western Denmark. *IEEE Transactions on Geoscience and Remote Sensing*, *51*, 2969–2985.
- dall'Amico, J. T., Schlenz, F., Loew, A., & Mauser, W. (2012). First results of SMOS soil moisture validation in the upper Danube catchment. *IEEE Transactions on Geoscience and Remote Sensing*, *50*, 1507–1516.
- de Rosnay, P., Calvet, J. C., Kerr, Y., Wigneron, J. P., Lemaitre, F., Escorihuela, M. J., ... Waldteufel, P. (2006). SMOSREX: A long term field campaign experiment for soil moisture and land surface processes remote sensing. *Remote Sensing of Environment*, *102*, 377–389.
- Durand, Y., Brun, E., Mérindol, L., Guyomarch, G., Lesaffre, B., & Martin, E. (1993). A meteorological estimation of relevant parameters for snow models. *Annals of Glaciology*, *18*, 65–71.
- Durand, Y., Laternser, M., Giraud, G., Etchevers, P., Lesaffre, B., & Mérindol, L. (2009). Re-analysis of 44 years of climate in the French Alps (1958–2002): Methodology, model validation, climatology and trends for air temperature and precipitation. *Journal of Applied Meteorology and Climatology*, *48*, 429–449.
- Ferrazzoli, P., Guerrero, L., & Wigneron, J. P. (2002). Simulating L-band emission of forests in view of future satellite applications. *IEEE Transactions on Geoscience and Remote Sensing*, *40*, 2700–2708.
- Hagolle, O., Sylvander, S., Huc, M., Claverie, M., Clesse, D., Dechoz, C., ... Poulain, V. (2015). SPOT-4 (take 5): Simulation of sentinel-2 time series on 45 large sites. *Remote Sensing*, *7*, 12242–12264.
- Hofer, R., & Good, W. (1979). Snow parameter determination by multichannel microwave radiometry. *Remote Sensing of Environment*, *8*, 211–224.
- Hofer, R., & Mätzler, C. (1980). Investigations on snow parameters by radiometry in the 3-mm to 60-mm wavelength region. *Journal of Geophysical Research-Oceans and Atmospheres*, *85*, 453–460.
- Jackson, T. J., Bindlish, R., Cosh, M. H., Zhao, T. J., Starks, P. J., Bosch, D. D., ... Leroux, D. (2012). Validation of soil moisture and ocean salinity (SMOS) soil moisture over watersheds networks in the U.S. *IEEE Transactions on Geoscience and Remote Sensing*, *50*, 1530–1543.
- Jackson, T. J., & Schmugge, T. J. (1991). Vegetation effects on the microwave emission of soils. *Remote Sensing of Environment*, *36*, 203–212.
- Jonard, F., Weihermüller, L., Jadoon, K. Z., Schwank, M., Vereecken, H., & Lambot, S. (2011). Mapping field-scale soil moisture with L-band radiometer and ground-penetrating radar over bare soil. *IEEE Transactions on Geoscience and Remote Sensing*, *49*, 2863–2875.
- Jonard, F., Weihermüller, L., Schwank, M., Jadoon, K. Z., Vereecken, H., & Lambot, S. (2015). Estimation of hydraulic properties of a sandy soil using ground-based active and passive microwave remote sensing. *IEEE Transactions on Geoscience and Remote Sensing*, *53*, 3095–3109.
- Kerr, Y. H., Waldteufel, P., Wigneron, J. P., Delwart, S., Cabot, F., Boutin, J., ... Mecklenburg, S. (2010). The SMOS mission: New tool for monitoring key elements of the global water cycle. *Proceedings of the IEEE*, *98*, 666–687.
- Kirdyashhev, K. P., Chukhlantsev, A. A., & Shutko, A. M. (1979). Microwave radiation of grounds with vegetative cover. *Radiotekhnika i Elektronika*, *24*, 256–264.
- Lafayesse, M., Morin, S., Coléou, C., Vernay, M., Serça, D., Besson, F., ... Durand, Y. (2013). Towards a new chain of models for avalanche hazard forecasting in French mountain ranges, including low altitude mountains. *Proceedings of the International Snow Science Workshop Grenoble – Chamonix Mont-Blanc – 2013, 7–11 October, Grenoble, France* (pp. 162–166).
- Lemmettyinen, J., Schwank, M., Rautiainen, K., Kontu, A., Parkkinen, T., Mätzler, C., ... Pulliaisen, J. (2015). Snow density and ground permittivity retrieved from L-band

- radiometry: Application to experimental data submitted to this SMOS special issue in RSE. .
- Louvet, S., Pellarin, T., al Bitar, A., Cappelaere, B., Galle, S., Grippa, M., ... de Rosnay, P. (2015). SMOS soil moisture product evaluation over west-Africa from local to regional scale. *Remote Sensing of Environment*, 156, 383–394.
- Macelloni, G., Brogioni, M., Pettinato, S., Zasso, R., Crepaz, A., Zaccaria, J., ... Drinkwater, M. (2013). Ground-based L-band emission measurements at dome-C Antarctica: The DOMEX-2 experiment. *IEEE Transactions on Geoscience and Remote Sensing*, 51, 4718–4730.
- Masson, V., et al. (2013). The SURFEXv7.2 land and ocean surface platform for coupled or offline simulation of earth surface variables and fluxes. *Geosci. Model Dev.*, 6(4), 929–960. <http://dx.doi.org/10.5194/gmd-6-929-2013>.
- Mätzler, C., & Standley, A. (2000). Relief effects for passive microwave remote sensing. *International Journal of Remote Sensing*, 21, 2403–2412.
- Malon, A., Coret, L., Kerr, Y. H., Secherre, F., & Wigneron, J. P. (2008). Flagging the topographic impact on the SMOS signal. *IEEE Transactions on Geoscience and Remote Sensing*, 46, 689–694.
- Malon, A., Richaume, P., Leroux, D., Bircher, S., Al Bitar, A., Pellarin, T., ... Kerr, Y. H. (2015). Comparison of Dobson and Mironov dielectric models in the SMOS soil moisture retrieval algorithm. *IEEE Transactions on Geoscience and Remote Sensing*, 53, 3084–3094.
- Mironov, V., Kerr, Y., Wigneron, J. P., Kosolapova, L., & Demontoux, F. (2013). Temperature- and texture-dependent dielectric model for moist soils at 1.4 GHz. *IEEE Geoscience and Remote Sensing Letters*, 10, 419–423.
- Mo, T., Choudhury, B. J., Schmugge, T. J., Wang, J. R., & Jackson, T. J. (1982). A model for microwave emission from vegetation-covered fields. *Journal of Geophysical Research-Oceans and Atmospheres*, 87, 1229–1237.
- Monerris, A., Benedicto, P., Vall-Ilossera, M., Camps, A., Santanach, E., Piles, M., & Prehn, R. (2008). Assessment of the topography impact on microwave radiometry at L-band. *Journal of Geophysical Research-Solid Earth*, 113.
- Pieschl, S., Walker, J. P., Rudiger, C., Ye, N., Kerr, Y. H., Kim, E., ... Allahmoradi, M. (2012). The AACES field experiments: SMOS calibration and validation across the Murrumbidgee River catchment. *Hydrology and Earth System Sciences*, 16, 1697–1708.
- Pellarin, T., Calvet, J. C., & Wigneron, J. P. (2003). Surface soil moisture retrieval from L-band radiometry: A global regression study. *IEEE Transactions on Geoscience and Remote Sensing*, 41, 2037–2051.
- Pellarin, T., Kerr, Y. H., & Wigneron, J. P. (2006). Global simulation of brightness temperatures at 6.6 and 10.7 GHz over land based on SMMR data set analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 44, 2492–2505.
- Picard, G., & Fly, M. (2006). Surface melting observations in Antarctica by microwave radiometers: Correcting 26-year time series from changes in acquisition hours. *Remote Sensing of Environment*, 104, 325–336.
- Pierdicca, N., Pulvirenti, L., & Marzano, F. S. (2010). Simulating topographic effects on spaceborne radiometric observations between L and X frequency bands. *IEEE Transactions on Geoscience and Remote Sensing*, 48, 273–282.
- Pulliajainen, J. T., Grandell, J., & Hallikainen, M. T. (1999). HUT snow emission model and its applicability to snow water equivalent retrieval. *IEEE Transactions on Geoscience and Remote Sensing*, 37, 1378–1390.
- Rautiainen, K., Lemmettyinen, J., Pulliajainen, J., Vehvilainen, J., Drusch, M., Kontu, A., ... Seppänen, J. (2012). L-band radiometer observations of soil processes in boreal and subarctic environments. *IEEE Transactions on Geoscience and Remote Sensing*, 50, 1483–1497.
- Rautiainen, K., Parkkinen, T., Lemmettyinen, J., Schwank, M., Wiesmann, A., Ikonen, J., ... Pulliajainen, J. (2015). SMOS prototype algorithm for detecting autumn soil freezing submitted to this SMOS special issue in RSE.
- Ridley, J. (1993). Surface melting on Antarctic peninsula ice shelves detected by passive microwave sensors. *Geophysical Research Letters*, 20, 2639–2642.
- Rudiger, C., Walker, J. P., & Kerr, Y. H. (2011). On the airborne spatial coverage requirement for microwave satellite validation. *IEEE Geoscience and Remote Sensing Letters*, 8, 824–828.
- Saleh, K., Wigneron, J. P., Waldteufel, P., de Rosnay, P., Schwank, M., Calvet, J. C., & Kerr, Y. H. (2013). Estimates of surface soil moisture under grass covers using L-band radiometry. *Remote Sensing of Environment*, 109, 42–53.
- Schlenz, F., dall'Amico, J. T., Loew, A., & Mauser, W. (2012). Uncertainty assessment of the SMOS validation in the upper Danube catchment. *IEEE Transactions on Geoscience and Remote Sensing*, 50, 1517–1529.
- Schwank, M., Mätzler, C., Guglielmetti, M., & Flühler, H. (2005). L-band radiometer measurements of soil water under growing clover grass. *IEEE Transactions on Geoscience and Remote Sensing*, 43, 2225–2237.
- Schwank, M., Wiesmann, A., Werner, C., Mätzler, C., Weber, D., Murk, A., ... Wegmüller, U. (2010). Elbara-II, an L-band radiometer system for soil moisture research. *Sensors MDPI*, 10, 584–612.
- Schwank, M., Wigneron, J. P., Lopez-Baeza, E., Völkisch, I., Mätzler, C., & Kerr, Y. (2012). L-band radiative properties of vine vegetation at the SMOS Cal/Val site MELBEX III. *IEEE Transactions on Geoscience and Remote Sensing*, 50, 1587–1601.
- Schwank, M., Wiesmann, A., Wegmüller, U., (2014), ELBARA-II Vercors reprocessing report, EOP-SM/2755/TC-tc, ESA.
- Schwank, M., Rautiainen, K., Mätzler, C., Stähli, M., Lemmettyinen, J., Pulliajainen, J., ... Wegmüller, U. (2014b). Model for microwave emission of a snow-covered ground with focus on L band. *Remote Sensing of Environment*, 154, 180–191.
- Skou, N., Misra, S., Balling, J. E., Kristensen, S. S., & Sobjaerg, S. S. (2010). L-band RFI as experienced during airborne campaigns in preparation for SMOS. *IEEE Transactions on Geoscience and Remote Sensing*, 48, 1398–1407.
- Utku, C., & Le Vine, D. M. (2011). A model for prediction of the impact of topography on microwave emission. *IEEE Transactions on Geoscience and Remote Sensing*, 49, 395–405.
- Van de Griend, A. A., & Wigneron, J. P. (2004). The b-factor as a function of frequency and canopy type at h-polarization. *IEEE Transactions on Geoscience and Remote Sensing*, 42, 786–794.
- Vionnet, V., Brun, E., Morin, S., Boone, A., Faroux, S., Le Moigne, P., ... Willemet, J.-M. (2012). The detailed snowpack scheme Crocus and its implementation in SURFEX v7.2. *Geosci. Model Dev.*, 5(3), 773–791. <http://dx.doi.org/10.5194/gmd-5-773-2012>.
- Völkisch, I. (2011). *Ground-based Remote Sensing of Land Surfaces – The Influence of Periodic Patterns and Relief on Thermal Microwave Emission*. Bern University 106p.
- Völkisch, I., Schwank, M., Stähli, M., & Mätzler, C. (2015). Relief effects on the L-band emission of a bare soil. *Remote Sensing*, 7, 14327–14359. <http://dx.doi.org/10.3390/rs71114327>.
- Wigneron, J.-P., Schwank, M., Lopez Baeza, E., Kerr, Y., Novello, N., Millan, C., ... Mecklenburg, S. (2012). First evaluation of the simultaneous SMOS and ELBARA-II observations in the Mediterranean region. *Remote Sensing of Environment*, 124, 26–37.
- Wigneron, J. P., Chanzy, A., Calvet, J. C., & Bruguier, W. (1995). A simple algorithm to retrieve soil-moisture and vegetation biomass using passive microwave measurements over crop fields. *Remote Sensing of Environment*, 51, 331–341.
- Wigneron, J. P., Laguerre, L., & Kerr, Y. H. (2001). A simple parameterization of the L-band microwave emission from rough agricultural soils. *IEEE Transactions on Geoscience and Remote Sensing*, 39, 1697–1707.
- Wigneron, J. P., Kerr, Y., Waldteufel, P., Saleh, K., Escorihuela, M. J., Richaume, P., ... Schwank, M. (2007). L-band microwave emission of the biosphere (L-MEB) model: Description and calibration against experimental data sets over crop fields. *Remote Sensing of Environment*, 107, 639–655.
- Zribi, M., Parde, M., Boutin, J., Fanise, P., Hauser, D., Dechambre, M., ... Tenerelli, J. (2011). CAROLS: A new airborne L-band radiometer for ocean surface and land observations. *Sensors*, 11, 719–742.

**F.1.2 Leroux et al. 2016 : Assimilation of SMOS soil moisture into a distributed hydrological model and impacts on the water cycle variables over the Ouémé catchment in Benin**



# Assimilation of SMOS soil moisture into a distributed hydrological model and impacts on the water cycle variables over the Ouémé catchment in Benin

Delphine J. Leroux<sup>1,2</sup>, Thierry Pellarin<sup>3,4</sup>, Théo Vischel<sup>3</sup>, Jean-Martial Cohard<sup>3</sup>, Tania Gascon<sup>3</sup>, François Gibon<sup>3</sup>, Arnaud Mialon<sup>2</sup>, Sylvie Galle<sup>3,5</sup>, Christophe Peugeot<sup>6</sup>, and Luc Seguis<sup>6</sup>

<sup>1</sup>CNES, LTHE, Laboratoire d'Étude des Transferts en Hydrologie et Environnement, Grenoble, France

<sup>2</sup>CNRS, CESBIO, Centre d'Etudes Spatiales de la Biosphère, Toulouse, France

<sup>3</sup>University Grenoble Alpes, LTHE, Grenoble, France

<sup>4</sup>CNRS, LTHE, Grenoble, France

<sup>5</sup>IRD, LTHE, Grenoble, France

<sup>6</sup>IRD, HydroSciences, Montpellier, France

Correspondence to: Delphine J. Leroux (delphine.j.leroux@gmail.com)

Received: 21 December 2015 – Published in Hydrol. Earth Syst. Sci. Discuss.: 19 January 2016

Revised: 9 May 2016 – Accepted: 16 June 2016 – Published: 14 July 2016

**Abstract.** Precipitation forcing is usually the main source of uncertainty in hydrology. It is of crucial importance to use accurate forcing in order to obtain a good distribution of the water throughout the basin. For real-time applications, satellite observations allow quasi-real-time precipitation monitoring like the products PERSIANN (Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks), TRMM (Tropical Rainfall Measuring Mission) or CMORPH (CPC (Climate Prediction Center) MORPHing). However, especially in West Africa, these precipitation satellite products are highly inaccurate and the water amount can vary by a factor of 2. A post-adjusted version of these products exists but is available with a 2 to 3 month delay, which is not suitable for real-time hydrologic applications. The purpose of this work is to show the possible synergy between quasi-real-time satellite precipitation and soil moisture by assimilating the latter into a hydrological model. Soil Moisture Ocean Salinity (SMOS) soil moisture is assimilated into the Distributed Hydrology Soil Vegetation Model (DHSVM) model. By adjusting the soil water content, water table depth and streamflow simulations are much improved compared to real-time precipitation without assimilation: soil moisture bias is decreased even at deeper soil layers, correlation of the water table depth is improved from 0.09–0.70 to 0.82–0.87, and the Nash coefficients of the streamflow go from negative to positive. Overall, the statistics tend to get closer

to those from the reanalyzed precipitation. Soil moisture assimilation represents a fair alternative to reanalyzed rainfall products, which can take several months before being available, which could lead to a better management of available water resources and extreme events.

## 1 Introduction

Surface soil moisture, as well as soil properties and precipitation intensity, is involved in the partitioning of rainfall into surface runoff and infiltration (water cycle), and also in the partitioning of the incoming solar and atmospheric radiations into latent, sensible and ground heat fluxes (energy cycle). It is therefore essential to correctly represent this amount of water contained in the soil in hydrological models.

Ground measurements of soil moisture are broadly used to monitor the hydrological cycle of a specific region. Like all in situ stations, the soil moisture probes need to be maintained and are most of the time installed for a limited amount of time. Moreover, the number of in situ measurements stays scarce, especially in tropical regions where the maintenance is even more complicated. Soil moisture monitoring from space has thus been developed for a larger/wider spatial coverage and assures continuity in time as long as the space mission is still operating. These two types are very complemen-

tary with in situ stations being able to directly measure soil moisture profiles at different depths and also used for satellite soil moisture validation.

In order to take advantage of these dedicated space missions, the hydrological model simulations can be merged with available observations through data assimilation. This technique has already been widely used by weather forecast models at regional and global scales, using remote sensing observations and ground measurements to improve weather forecasting.

Numerous studies have been devoted to use soil moisture assimilation into hydrological and land surface models for various applications. With the availability of more than 35 years of soil moisture at the global scale derived from a series of satellites (SMMR, SSM/I, TRMM-TMI, AMSR-E, ASCAT, Windsat; Liu et al., 2011, 2012; Wagner et al., 2012), the soil moisture CCI (Climate Change Initiative by ESA; Hollmann et al., 2013) has been assimilated in many models for hydrological purposes such as streamflow simulation (Pauwels et al., 2001, 2002), flood events prediction via runoff simulation (Brocca et al., 2010, 2012), drought prediction (Kumar et al., 2014) and root zone soil moisture simulations (Draper et al., 2012; Renzullo et al., 2014; Parrens et al., 2014) for a better prediction of agricultural yields (Chakrabarti et al., 2014). Han et al. (2012) voluntarily degraded the precipitation input and showed that soil moisture, water table depth (WTD) and evapotranspiration simulations could be improved by assimilating surface soil moisture. As in most of the soil moisture assimilation studies, Ridler et al. (2014) have also found that it improves the distribution of the soil moisture simulations.

More recently, Wanders et al. (2014) and Lievens et al. (2015) assimilated the Soil Moisture Ocean Salinity (SMOS) soil moisture product into hydrological models. The first study assessed the impact of the joint assimilation of remotely sensed soil moisture (ASCAT (Advanced SCATTERometer), AMSR-E (Advanced Microwave Scanning Radiometer - Earth observing system) and SMOS (Soil Moisture and Ocean Salinity)) on the flood predictions over the upper Danube basin using the distributed hydrological LIS-FLOOD model for operational services. They showed that soil moisture observations improved the quality of flood alerts, both in terms of timing and of peak heights. They also reduced the number of false flood alarms. Lievens et al. (2015) assimilated the SMOS soil moisture product into the VIC (Variable Infiltration Capacity) model over the Murray–Darling basin, Australia, which is around 1 million km<sup>2</sup>. While the model was calibrated using 169 discharge stations, the streamflow simulations were good at the monthly scale but poor on a daily basis. Assimilation of soil moisture improved the soil moisture simulations, and hence the runoff generation, which finally had a positive impact on the streamflow simulations, especially during the runoff peak time periods.

Assimilation is of particular interest for regions where water management is vital, whereas in situ hydrological data are scarce. This is the case in the West African region, which faces major water-related risks (drought, floods, famine, diseases) threatening the population safety and slowing down the economical development. At the same time, the region is notoriously known to be lacking in in situ hydrological data, which limits the possibility to properly address the water management issues.

For operational applications, real-time hydrological modeling is needed and this requires one to have real-time observations and information. Various real-time observations exist but may lack accuracy with biases that will impact all the hydrologic variables, and reanalyzed versions are made available several weeks to months after the actual observations. Precipitation forcing is the main source of uncertainty in hydrological modeling.

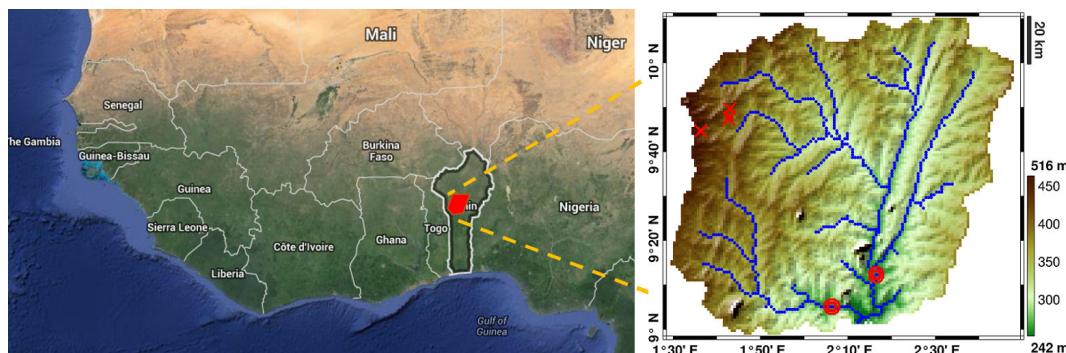
We propose a methodology to correct for the inaccurate amount of water brought by the real-time precipitation forcing by assimilating the SMOS soil moisture products. They are available within 10 days after the observations, and could be used for hydrological applications until the reanalyzed precipitation are released. This work will focus on the Ouémé catchment located in Benin, West Africa, which is presented in the first part along with the rainfall and soil moisture satellite products. The second part describes the hydrological model and the data assimilation method. Then the impact on the simulations of the soil moisture, the water table depth and the streamflow is discussed.

## 2 Study area and satellite data

### 2.1 The Ouémé catchment and the in situ measurements

The Ouémé catchment is located in Benin, West Africa, and is part of the AMMA-CATCH observatory (African Monsoon Multidisciplinary Analysis – Coupling the Tropical Atmosphere and the Hydrological Cycle; Lebel et al. (2009); <http://www.amma-catch.org>), whose objective is to study the hydrological impact of climate and anthropogenic changes. With a size of 12 000 km<sup>2</sup>, the Ouémé catchment is mainly covered by savanna, forests and cultures. The rainy season spreads from April to October for an annual amount of around 1250 mm. Streamflow is permanent from July to November. The basin is on basement. The hard-rock aquifer is unconfined and its recharge is annual. This basin is highly instrumented in order to monitor the water cycle and the vegetation dynamic in this sub-humid region.

Soil moisture is measured at three locations indicated by red crosses in Fig. 1: Nalohou, Belefoungou and Bira. Every hour, time-domain reflectometry sensors measure the soil response to an electric pulse at various depths (from 5 cm to 1.2 m). Soil moisture values can be retrieved after correc-



**Figure 1.** The Ouémé catchment is located in Benin, West Africa. Indicated on the right panel is the location of three soil moisture stations in the northwestern part (red crosses) where water table depth is also measured, and two streamflow sensors installed in the southern part (red circles, the outlet total streamflow being the sum of the two stations measurements).

tion for the soil temperature impact and by using wet and dry samples from the different ground sites. For two of these sites, flux stations are also installed measuring the evapotranspiration every 30 min using eddy correlation sensors.

The water table, which is defined as the interface between unsaturated and saturated soil, is measured manually every 2 days on a network of observation wells close to the soil moisture sites (Seguis et al., 2011).

Water levels from the rivers are measured every hour at two locations (indicated by the two red circles in Fig. 1) representing the outlets of the two sub-basins of the Ouémé catchment: Côte 238 and Beterou. For each site, a calibration has been realized to convert the water level into a streamflow value using an acoustics Doppler current profiler. The total streamflow is supposed to be the sum of the measurements at these two points as the contribution between the real outlet of the whole basin and the points of measurement is negligible.

The rainfall monitoring is ensured by a dense network of rain gauges (tipping bucket). For the study of years 2010–2012, 33 evenly distributed rain gauges were operating. Their measurements have been treated in order to produce 1 h rainfall series that have then been spatially interpolated over a regular  $0.05^\circ$  resolution grid based on Lagrangian kriging (Vischel et al., 2011). Since the rain gauge network is dense enough, the use of interpolated rain fields to force hydrological models is relevant and can help to produce simulations of reference (Vischel and Lebel, 2007; Gascon et al., 2015).

## 2.2 Satellite rainfall products

In most cases and more particularly for tropical and semi-arid regions, there are not enough rain gauges to cover the entire basin and precipitation observed by satellite can be used. Many satellite products are available and three have been used in this study.

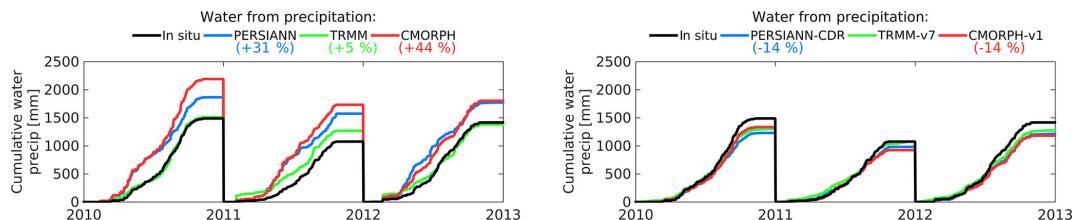
The PERSIANN (Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks, v. 300 and 301; Hsu et al., 1997; Sorooshian et al., 2000) product is

an estimation of the rainfall rate, used here at a  $0.25^\circ$  resolution every 3 h, based on infrared satellite observations coupled to ground observations from gauges and radars operating at various frequencies. Some studies have already shown that this rainfall product does not perform well everywhere (Ward et al., 2011; Thiemig et al., 2012).

A second satellite product has been used for precipitation forcing data: the TRMM (Tropical Rainfall Measuring Mission) Near-Real-Time 3B42RT (v7; Huffman et al., 2007), which combines microwave and infrared satellite observations and is available at a  $0.25^\circ$  resolution and a 3 h time step. This product has been widely used in various hydrological studies (Khan et al., 2011; Li et al., 2012) and has the advantage to combine two sources of data compared to the PERSIANN product. For the sake of simplicity, the TRMM Near-Real-Time 3B42RT product is referred as the TRMM product in the following.

CMORPH (CPC MORPHing from NOAA; Joyce et al., 2004) is the third precipitation product used here. This method uses rainfall estimates that have been derived from low-orbit satellite microwave observations, and infrared observations from geostationary satellites in order to produce a merged and unique rainfall data set. The CMORPH product that has been selected is available at a  $0.25^\circ$  resolution and a 3 h time step.

PERSIANN, TRMM and CMORPH are the quasi-real-time precipitation forcing products used in this study (referenced as RT). They usually are available within a few hours after the actual observations. Their post-adjusted or reanalyzed versions (PERSIANN-CDR, TRMM-v7 and CMORPH-v1) are generated by adding external information like in situ rain gauge measurements or soil radar observations (referenced as RE). They are generally more accurate but are only available 2 to 3 months after the actual observations, which is not compatible with real-time applications most of the time. Figure 2 shows the cumulative amounts of water brought by the different satellite products compared to the in situ measurements in average over the whole basin.



**Figure 2.** Cumulative average precipitation amount over the whole basin from the in situ network (black) and the three satellite product from quasi-real-time versions (left panel) and their reanalyzed versions (right panel): PERSIANN (blue), TRMM (green) and CMORPH (red).

While the RT products (left panel) overestimate the precipitation amount, the reanalyzed products slightly underestimate (right panel). The largest difference between in situ and satellite rainfall occurs in the second quarter of the year for the PERSIANN and CMORPH products, which is just before the monsoon period and might saturate the soil earlier than it should, leading to high values of runoff and discharge. For all the RT products, the dry season is not well represented even if the rainfall amount is much lower than during the rainy season. These positive biases were already identified in Gosset et al. (2013) and Casse et al. (2015). The distribution of the precipitation of the reanalyzed products is, however, much improved in the reanalyzed products (not shown here).

### 2.3 SMOS soil moisture product

The SMOS mission has been producing soil moisture products for more than 5 years, observing the entire globe every 3 days at a resolution of around 40 km. Thanks to the multi-angular observations and the sensitivity of the L-band frequency to the soil water content, the soil moisture is retrieved with a target accuracy of  $0.04 \text{ m}^3 \text{ m}^{-3}$ . More details can be found about the soil moisture retrieval algorithm in Kerr et al. (2012).

The SMOS level 3 soil moisture product (second reprocessing, v. 2.7, 1-day product; Jacquette et al., 2010) used in this study is provided by CNES-CATDS (Centre Aval de Traitement des Données SMOS) on the EASE-Grid 2.0 (Equal-Area Scalable Earth) at 25 km resolution. This product is usually available within 10 days. In Louvet et al. (2015), it was found that the SMOS L3 product is the most suitable and available satellite soil moisture product compared to in situ measurements collected in West Africa from 2010 to 2012.

## 3 Model and data assimilation

### 3.1 DHSVM model

For the Ouémé catchment, Seguis et al. (2011) shows a major contribution of lateral water flows in the hydrological processes, especially during the spring season. The Distributed Hydrology Soil Vegetation Model (DHSVM, developed at

the University of Washington; Wigmosta et al., 1994) has been selected for its capability of water lateral redistribution from and to the neighboring pixels.

DHSVM solves the energy and water balances at each grid cell and time step with a physically based model representing the effect of topography, soil and vegetation. The outputs are the soil moisture, the snow quantity (not used nor showed here), the streamflow, the evapotranspiration and the runoff. This model has already been used in many previous studies (Whitaker et al., 2003; Cuo et al., 2006; Cuartas et al., 2012; Du et al., 2014; Gascon et al., 2015) showing its capability to simulate various hydrological components such as the snowpack, the streamflow, the water table depths or the soil moisture. All these studies also emphasized the importance of the model parameter calibration step and the accuracy of the meteorological input data.

DHSVM has been used in this study at a resolution of 1 km with an hourly time step and four soil layers at the following depths: 1, 5, 40 and 80 cm. The first layer has been set for numerical reasons, the second is used for the assimilation, and the two deeper layers are used for validation with in situ measurements. It also needs meteorological inputs for the following variables: relative humidity, air temperature, wind speed, pressure, shortwave and longwave radiation. The reanalysis MERRA (Modern-Era Retrospective analysis for Research and Applications) products from NASA have been used in this study (Rienecker et al., 2011). These products are available hourly at a 1/2 and 2/3° resolution in latitude and longitude, and have been produced using the Goddard Earth Observing System Model (GEOS-5, version 5) and the Atmospheric Data Assimilation System (ADAS, version 5.2.0).

The DHSVM model has many parameters, which could be measured in situ or, if no measurement is available, can be estimated based on soil characteristics and vegetation covers. Previous studies (Whitaker et al., 2003; Cuo et al., 2006; Cuartas et al., 2012; Du et al., 2014) described precisely their DHSVM model parameter values using in situ radiation, soil moisture and streamflow measurements for calibration. It was often noticed that it was difficult to obtain good soil moisture and streamflow simulations simultaneously, and that streamflow simulations could be improved at the expense of the soil moisture simulations (Cuo et al., 2006).

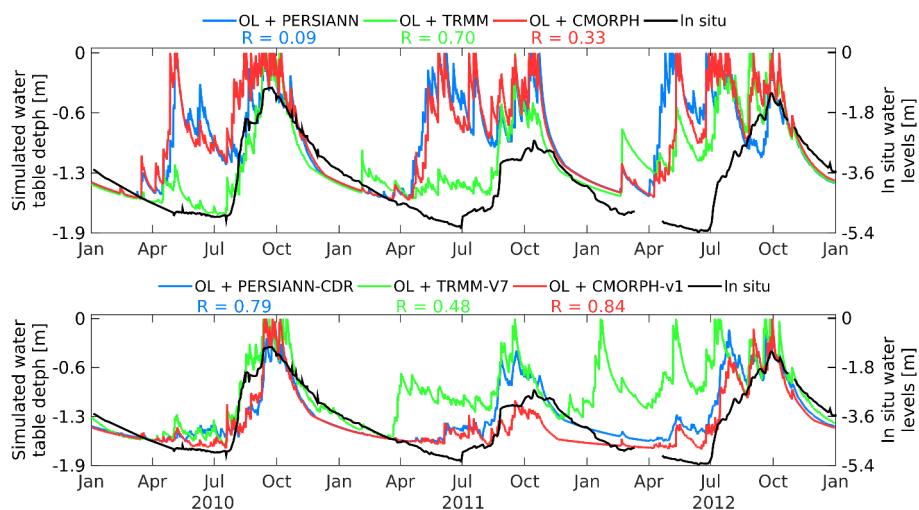
**Table 1.** DHSVM soil and vegetation parameter values (understory and overstory) after calibration. The marker \* indicates the parameters that have been re-estimated for the whole basin compared to Gascon et al. (2015).

Soil parameters		Vegetation parameters		
		Under.	Over.	
Lateral saturated hydraulic conductivity* [m s <sup>-1</sup> ]	$5 \times 10^{-2}$	Canopy coverage [fraction]	0.9	
		trunk space [fraction]	0.4	
Exponential decrease rate of lateral saturated hydraulic conductivity* [-]	2	Aerodynamic extinction factor for wind through overstory [fraction]	3.5	
Max. infiltration rate* [m s <sup>-1</sup> ]	$2 \times 10^{-4}$	Radiation attenuation by	0.5	
Soil surface albedo [-]	0.1	Vegetation [fraction]		
Porosity* [fraction, 4 layers]	0.5, 0.5, 0.5, 0.5	Vegetation height [m]	0.5	6
Bulk density [kg m <sup>-3</sup> , 4 layers]	1485, 1485, 1485, 1485	Fraction of shortwave radiation photosynthetically active ( $R_{pc}$ )	0.108	0.108
Field capacity* [m <sup>3</sup> m <sup>-3</sup> , 4 layers]	0.15, 0.20, 0.25, 0.35	Root zone depths [m]	0.01, 0.05, 0.40, 1.0	
Wilting point* [m <sup>3</sup> m <sup>-3</sup> , 4 layers]	0.02, 0.04, 0.08, 0.12	SM threshold above which transpiration is not	0.10	0.30
Vertical saturated hydraulic conductivity* [m s <sup>-1</sup> , 4 layers]	$10^{-7}, 10^{-6}, 10^{-6}, 10^{-6}$	Restricted [m <sup>3</sup> m <sup>-3</sup> ] vapor pressure deficit	3000	2500
Thermal conductivity [W m <sup>-1</sup> K <sup>-1</sup> , 4 layers]	7.114, 7.114, 7.114, 7.114	Threshold above which stomatal closure occurs [Pa]		
Thermal capacity [J m <sup>-3</sup> K <sup>-1</sup> , 4 layers]	$1.4 \times 10^6, 1.4 \times 10^6, 1.4 \times 10^6, 1.4 \times 10^6$			

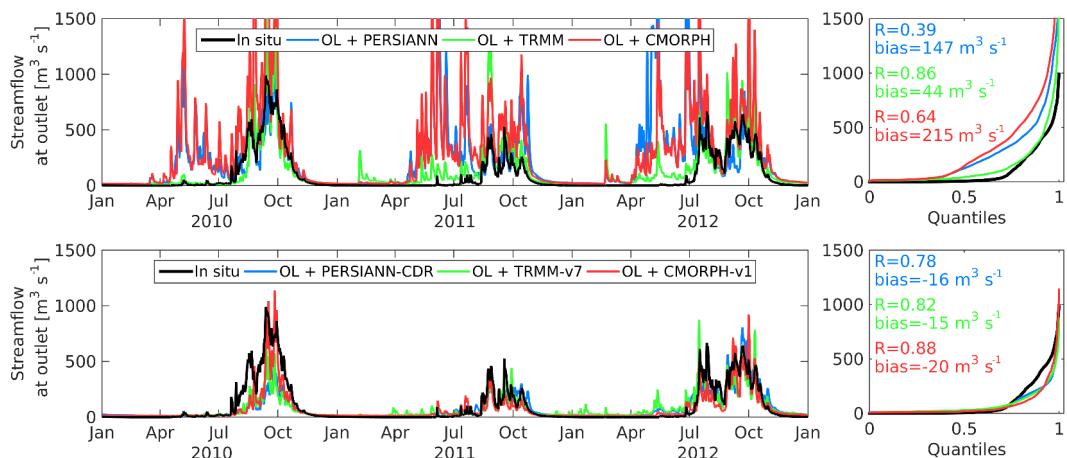
In Gascon et al. (2015), DHSVM parameterization was realized using in situ streamflow measurements at the Cote 238 station for 2005, which represents 25 % of the whole basin (Beterou station being on the main course of the Ouémé river). This parameterization has been used as a starting point for this study. Here, the model has different soil layers and has been calibrated using in situ measurements from 2010 (soil moisture from the three stations, streamflow at the outlet, and evapotranspiration from one station). In order to ingest the correct amount of water for the calibration process, the interpolated in situ rainfall data have been used. Table 1 represents the main soil and vegetation characteristics used in this study for the DHSVM model after calibration for the whole basin. These parameter values have been optimized using a semi-automatic protocol; i.e., multiple sets of values have been tested and the one giving the best performance has been chosen. Model outputs have been evaluated at different locations in the basin (from various stations) using soil moisture ( $R = 0.81$ , RMSE = 0.084 m<sup>3</sup> m<sup>-3</sup>), streamflow ( $R = 0.94$ , RMSE = 81.7 m<sup>3</sup> s<sup>-1</sup>, Nash = 0.87) and evapotranspiration ( $R = 0.81$ , RMSE = 166.7 W m<sup>2</sup>) in situ measurements.

As mentioned in Bitew and Gebremichael (2011), calibrating a model using biased satellite precipitation will lead to a set of parameters that will compensate for the modified runoff generated by the under or overestimated volume of water brought by the satellite product compared to the in situ measurements. Adjusting the model parameters can compensate for the rainfall errors but the global water budget will be deteriorated and the other hydrological processes will be disturbed. For this reason, the model calibration has only been performed with the in situ precipitation, which leads to a correct partitioning of the precipitation between infiltration and runoff. Similar results were found when adjusted satellite products were used and close statistic scores were obtained (see Fig. 3 for water table depth and Fig. 4 for streamflow simulations). The term *open-loop* refers to simulations with no assimilation.

One of the five outputs of DHSVM is the water table depth. Groundwater is an important resource, especially in West Africa where most of the drinking water comes from the ground. Moreover, the precipitation interannual variability can be important (1560 mm in 2010 followed by only 1100 mm in 2011 and 1450 mm in 2012 from the in situ rain gauge measurements), which has a strong impact on ground-



**Figure 3.** Open-loop (OL) water table depth simulations using the RT (top panel) and reanalyzed (bottom panel) satellite precipitation products as forcing compared to in situ measurements at Nalohou. For comparison, the water table depth simulations using in situ precipitation as forcing (not shown here) lead to a correlation of 0.76.



**Figure 4.** Open-loop (OL) streamflow simulations using the RT and reanalyzed satellite precipitation products as forcing. Statistics are given on the right panel. For comparison, the streamflow simulations using in situ precipitation as forcing (not shown here) lead to a correlation of 0.92 for a bias of  $32 \text{ m}^3 \text{s}^{-1}$ .

water recharge. The water table depth can vary between the soil depth and the ground surface (in the latest case, an exfiltration or a flooding can happen). Sensitivity tests have been realized for the Ouémé catchment with many years of spin-up for various soil depth values and the maximum water table depth was always found around 1.90 m. After these yearly spin-ups, water was filling the soil until its natural equilibrium. The water table depth does not depend on the soil depth but on the ability of the model to evacuate this saturated water through the defined hydrological network, the root density and the topography (physical processes are explained in Seguis et al., 2011).

Figure 3 shows the simulations of the water table depth using the different precipitation products at Nalohou (sta-

tion selected for the availability of its measurements along the three years of study, and can be compared to simulations from the closest model  $1 \text{ km}^2$  pixel). Simulated water table depths and water levels from wells are not quite comparable but they should follow the same time evolution (certainly because of the difference in porosity values set in the model and what is observed in reality). In order to compare both quantities, they are represented on the same graph but not at the same scale. The left y axis represents the depth of the water as simulated by the model, whereas the right y axis represents the in situ water level as measured in the observation well with a maximum of 5.40 m. Correlation scores are not impacted by scaling and they are indicated directly on the figure.

Using the RT precipitation (top panel), the water table depth is correctly simulated until the first rainfalls when the soil is quickly saturated due to the inaccurately high amount of water brought by the RT products, which then percolates to the deep soil layers. The soil is completely saturated in early May with a simulated water table reaching the surface. The correlation scores are very low for PERSIANN and CMORPH (0.09 and 0.33), whereas the TRMM product gives fair simulations with a correlation of 0.70. Using the reanalyzed precipitation (bottom panel), the time evolution is improved and most of the early peaks are smoothed. The correlations are higher for PERSIANN (0.79) and CMORPH (0.84), whereas it is lower for TRMM (0.48) due to inaccurate precipitation event in spring 2011 and in winter–spring 2012.

Figure 4 shows the simulations of the streamflow at the outlet of the basin compared to the in situ measurements. Using the RT precipitation (top panel), the streamflow is highly impacted by the runoff caused by the saturated soil from the inaccurate rainfall events, and it becomes very sensitive to any additional amount of water. This is the reason for these high and quick changes in the streamflow time series. When the reanalyzed precipitation is used (bottom panel), the time evolution is much closer to the in situ measurements. The simulations are a bit underestimated in 2010, but then correct for 2011 and 2012. PERSIANN and CMORPH simulations are improved by the reanalysis with a correlation from 0.39 and 0.64 to 0.78 and 0.88, respectively, with a bias divided by 10. Correlation using TRMM is a bit lower using the reanalyzed product (from 0.86 to 0.82) but the bias is still divided by 3. The simulations using the in situ precipitation (not shown here) give a correlation of 0.92 for a bias of  $32 \text{ m}^3 \text{ s}^{-1}$ , which is a bit higher than the reanalyzed precipitation products for the correlation but a bit lower for the bias. The statistics' performances from the reanalyzed products and from the in situ precipitation are about the same, showing that the parameterization of the model is adequate for both forcing.

It is not expected from the RT precipitation products to generate simulations as good as the reanalyzed precipitation, but Figs. 3 and 4 show the room for improvement that can be realized between the two versions of the satellite precipitation products by the assimilation.

### 3.2 Assimilation method: the optimal interpolation

SMOS soil moisture is assimilated into the DHSVM model using an optimal interpolation method (simplification of the Kalman filter where the errors are assumed to be known). In this study, the “3D-Cm” method proposed in De Lannoy et al. (2010) and successfully used in Sahoo et al. (2013), is applied here. The “3D-Cm” scheme consists in assimilating multiple coarse-scale observations (25 km), which implies an aggregation of the model from the fine scale (1 km) to the SMOS scale but avoids artificial transitions at the pixel

boundaries by using multiple coarse-scale observations to update the finer-scale simulations. Some of the key equations of the assimilation method are detailed in this article but more information can be found in De Lannoy et al. (2010) or in Sahoo et al. (2013).

Based on the difference between the simulations and the observations, the model background predictions are updated depending on their respective error covariances. Ensemble methods can estimate these error covariances from a Monte Carlo ensemble generation but in this study, a simpler method has been applied and fixed values of the error covariances are used.

Before being assimilated and for an optimal analysis (Yilmaz and Crow, 2013), the SMOS soil moisture product has been rescaled to remove any systematic bias using the open-loop model simulations. In this study, a CDF (cumulative density function) matching at SMOS scale has been applied for each pixel independently for each year according to the open-loop variability. Also, the ascending (06:00 LST – local solar time) and the descending (18:00 LST) observations have been treated separately.

At each time step  $i$  a SMOS observation is available, the forecast state vector  $\hat{x}_i^-$  including the soil moisture at the four model soil depths (1, 5, 40 and 80 cm) is mapped from the fine model scale (1 km) to the coarse SMOS scale (25 km) to calculate the prediction at the observation scale  $H\hat{x}_i^-$ , where  $H$  is called the observation operator. As in De Lannoy et al. (2010) or Sahoo et al. (2013), a simple spatial mean is applied here. The difference between the observation and the prediction at the coarse scale, called the innovation ( $y_i - H\hat{x}_i^-$ ), is used to update the finer model pixels  $\hat{x}_i^+$  called the analysis using a gain matrix  $\mathbf{K}$ . The update equation at time step  $i$  for a given fine-scale pixel  $k$  is as follows:

$$\hat{x}_i^{k+} = \hat{x}_i^{k-} + K_i^k [y_i - H\hat{x}_i^-], \quad (1)$$

where the gain matrix  $\mathbf{K}$  depends on the model error covariance  $B$  and the observation error covariance after rescaling  $R$ :

$$\mathbf{K} = \frac{BH^T}{HBH^T + R}. \quad (2)$$

The model error covariance matrix  $\mathbf{B}$  is calculated separately for each pixel of the model grid based on the DHSVM open-loop simulations ( $B_{ij} = \text{Cov}(\text{SM}_i, \text{SM}_j)$ ). The average  $\mathbf{B}$  matrix is as follows:

$$\mathbf{B} = \begin{bmatrix} 0.022 & 0.015 & 0.010 & 0.003 \\ 0.015 & 0.019 & 0.011 & 0.003 \\ 0.010 & 0.011 & 0.012 & 0.005 \\ 0.003 & 0.003 & 0.005 & 0.006 \end{bmatrix} (\text{m}^3 \text{ m}^3)^2. \quad (3)$$

The SMOS observation error covariance matrix  $\mathbf{R}$  is evaluated for each node of the SMOS grid using all the available SMOS observations.  $\mathbf{R}$  is supposed to be diagonal and represents the variance of the observations. The average variance of the SMOS observations is  $0.017 (\text{m}^3 \text{ m}^{-3})^2$ .

Finally, the observation matrix  $\mathbf{H}$  consists of four columns (for the four soil layers) times the number of available observations for the number of lines. Since the assimilation is performed on the second soil layer, the second column  $\mathbf{H}$  should be filled with the same equal value if all SMOS observations had the same influence on the model grid point of interest (sum of these values equal to 1). For this reason, a weighing function is used depending on the distance between the SMOS observation and the concerned model point such as shown in Fig. 5.

Here,  $y_i$  contains as many SMOS observations as are within a given radius (60 km) and those observations have a larger impact if they are closer to the considered model pixel to update. As in Reichle and Koster (2003) and De Lannoy et al. (2010), a fifth-order polynomial function (Eq. (4.10) of Gaspari and Cohn, 1999) based on the distance between two points and on a compact support radius is applied to weigh the influence of SMOS observations in  $H$  (Gaspari function, red line in Fig. 5). This equation is really close to the SMOS mean weighting function used to model the antenna pattern in the SMOS retrieval algorithm (Kerr et al. (2015), blue line in Fig. 5).

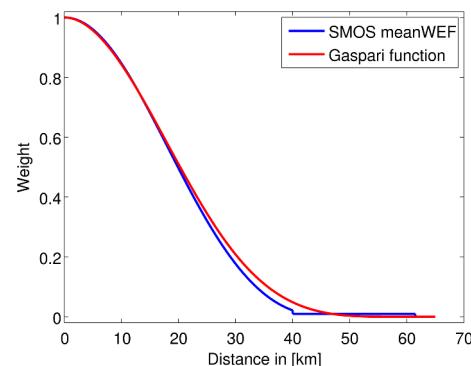
The SMOS observations are assimilated in the second soil layer of the model (1–5 cm) since it is more representative of what is observed by the SMOS instrument (Kerr et al., 2012). The correlations between the different soil layers being contained in  $K$ , the other soil layers (1, 40 and 80 cm) are also updated during the same time step but with a lower influence from the SMOS observations. The other model variables such as the evapotranspiration and the streamflow are not updated through the assimilation step but are updated with the propagation of these modifications in the model, i.e., if water is removed from the ground, the lateral subsurface flow and the streamflow should decrease too.

### 3.3 Statistics metrics

In order to quantify the performances of the model simulations and the impact of the SMOS soil moisture assimilation, five statistics metrics have been chosen in this study: the temporal correlation  $R$ , the bias, the standard deviation of the difference between the simulations and the in situ measurements (sdd), the root mean square errors ( $\text{RMSE} = \sqrt{\text{bias}^2 + \text{sdd}^2}$ ) and the Nash model efficiency coefficient as defined in Nash and Sutcliffe (1970) for streamflow simulation skill. These statistics have been computed using all common dates available.

## 4 Results and discussion

This section presents the impact of the SMOS soil moisture assimilation on different variables: soil moisture at multiple depths (control variables) at the Bira station, water table depth at the Nalohou station, and streamflow at the out-



**Figure 5.** Weighing functions for the observation matrix  $\mathbf{H}$  comparing the function used for the SMOS antenna pattern and the Gaspari function used in this study.

let. The simulations and performances after assimilation are compared to the open-loop simulations in the objective to reach those from the reanalyzed precipitation products.

### 4.1 Correction of the control variable: the soil moisture

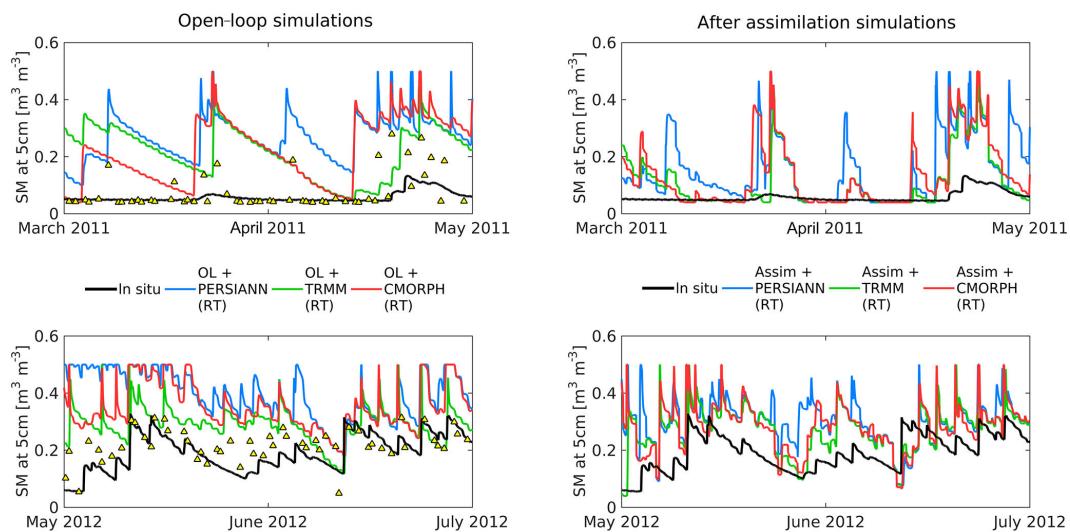
The first variables to be impacted by the assimilation of SMOS products are the ones directly contained in the state vector of the assimilation scheme; i.e., the soil moisture of the four defined soil layers at 1, 5, 40 and 80 cm. Soil moisture simulations are shown in Fig. 6 at 5 cm depth for two time periods: the upper panel represents the time series of March–April 2011 (beginning of the rain season), and the lower panel May–June 2012 (wet season). The left side shows the open-loop simulations, whereas the after-assimilation results are on the right side. For visual clarity, the 3 years of simulations are not shown here but these two time periods are representative of the effect of the assimilation on the soil moisture variable.

As mentioned before, the RT satellite rainfall products bring too much water during the winter and spring seasons. The first time period (top panel of Fig. 6) is a good example of a soil moisture increase after a rainfall detected by the satellite product (at the beginning of March for example), which has not happened in reality. The simulated soil moisture is thus impacted by this fake rain event with an increase. By assimilating SMOS soil moisture product at the surface, the impact of this wrong rainfall event is smoothed but has not completely disappeared. The wet season example also shows the same process. These wrong increases cannot be corrected by the assimilation but the drying phases can be fastened as post-event corrections.

Table 2 gathers the statistic scores of all the precipitation cases (RT, RT after assimilation, and RE) for the 3 years and the three layers at the Bira station. As it can be seen in Fig. 6, the continuity in the soil moisture time series cannot always be preserved by the assimilation method applied here, which results in abrupt changes before and after the time step when

**Table 2.** Statistics of the simulated soil moisture at 3 depths (5, 40 and 80 cm) compared to the in situ measurements at the Bira station for 2010–2012. Three cases are considered: open-loop simulations using real-time satellite precipitation (RT), assimilation of SMOS soil moisture with real-time precipitation (RT + SMOS) and open-loop simulation using reanalyzed precipitation (RE). Bias, standard deviation of the difference (sdd) and root mean square error (RMSE) are in  $\text{m}^3 \text{ m}^{-3}$ , the correlation ( $R$ ) is dimensionless. Bold font is used when the bias is improved by the assimilation.

SM	PERSIANN			TRMM			CMORPH		
	RT	RT + SMOS	RE	RT	RT + SMOS	RE	RT	RT + SMOS	RE
(5 cm)									
$R$	0.60	0.73	0.81	0.72	0.81	0.54	0.76	0.78	0.76
bias	0.091	<b>0.062</b>	0.073	0.051	0.051	0.123	0.089	<b>0.056</b>	0.041
sdd	0.119	0.091	0.091	0.098	0.082	0.102	0.102	0.086	0.088
RMSE	0.150	0.110	0.117	0.110	0.096	0.160	0.136	0.103	0.097
(40 cm)									
$R$	0.62	0.65	0.89	0.75	0.72	0.65	0.76	0.67	0.87
bias	0.119	<b>0.052</b>	0.056	0.086	<b>0.071</b>	0.129	0.128	<b>0.064</b>	0.033
sdd	0.085	0.099	0.058	0.068	0.094	0.064	0.072	0.101	0.058
RMSE	0.146	0.112	0.081	0.110	0.117	0.144	0.147	0.120	0.067
(80 cm)									
$R$	0.64	0.49	0.63	0.52	0.42	0.36	0.69	0.50	0.57
bias	0.194	<b>0.102</b>	0.114	0.154	<b>0.136</b>	0.192	0.200	<b>0.131</b>	0.068
sdd	0.064	0.126	0.084	0.083	0.115	0.088	0.056	0.119	0.097
RMSE	0.204	0.162	0.142	0.175	0.178	0.211	0.208	0.177	0.119



**Figure 6.** Comparison between the simulations of soil moisture at 5 cm depth at the Bira station at two different time periods: dry season in 2011 (upper panel), and the beginning of the raining season in 2012 (lower panel). The open-loop simulations are represented on the left whereas the simulated soil moisture after assimilation are on the right. The different rainfall products are indicated with various colors. Assimilated SMOS observations are indicated by yellow triangles on the left panel.

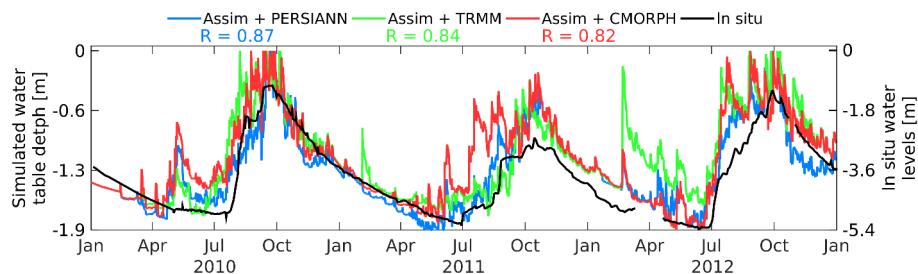
the assimilation is performed. This discontinuity has a negative artificial impact on the correlation, the standard deviation and the root mean square error. The bias is the only statistical metric that can be used to truly assess the impact of the as-

simulation on the soil moisture variable. The other statistics are shown for indication in Table 2.

Using the RT satellite precipitation products, the bias is always reduced after the assimilation. At 5 cm depth, it is improved by 0 % (TRMM) to 37 % (CMORPH), at 40 cm

**Table 3.** Statistics of the simulated water table depth (WTD) compared to the in situ measurements at the Nalohou station for 2010–2012. Three cases are considered: open-loop simulations using real-time satellite precipitation (RT), assimilation of SMOS soil moisture with real-time precipitation (RT + SMOS), and open-loop simulation using reanalyzed precipitation (RE). Since the simulations and the in situ measurements are not directly comparable, only the correlation ( $R$ ) is shown here. Improvement of the correlation is indicated in bold font.

WTD	PERSIANN			TRMM			CMORPH		
	RT	RT + SMOS	RE	RT	RT + SMOS	RE	RT	RT + SMOS	RE
$R$	0.09	<b>0.87</b>	0.79	0.70	<b>0.84</b>	0.48	0.33	<b>0.82</b>	0.84



**Figure 7.** Simulations of the water table depth at the Nalohou station (in situ measurements in black) using RT precipitation for after SMOS assimilation (in colors). Correlations are also indicated in the figure.

depth by 17 % (TRMM) up to 56 % (PERSIANN), and at 80 cm, by 12 % (TRMM) up to 47 % (PERSIANN). The biases are even lower than with PERSIANN and TRMM reanalyzed products. This shows that the assimilation and the model are able to propagate the information from the 5 cm layer to the deeper layers of the soil. The largest improvements are naturally obtained when the PERSIANN and the CMORPH products are used as precipitation forcing since there are the ones bringing the most extra water in the model. This proves that assimilation can correct for this additional amount of water. Moreover, the open-loop simulations show unrealistic soil saturation at the 5 cm layer during the rain season (soil moisture value is equal to porosity, see Fig. 6), which is also the case at deeper layers later in the season (not shown here). This saturation issue is improved after assimilation, but can still happen.

Assimilation does not correct directly the precipitation: neither for the amount of water nor for the time of the event itself. So the volume of water given to the model remains the same and the peaks in the soil moisture simulations cannot be corrected until a SMOS observation becomes available, and only the drying phase can then be modified.

The impact of the assimilation on the evapotranspiration variable has also been studied but not shown here. The changes in evapotranspiration were very small after the assimilation using the real-time precipitation products: it was overestimated before (+3 to +9 %) and was still after (around +9 %) for all products.

#### 4.2 Impact on the water table depth simulations

Figure 7 shows the simulations of the WTD after SMOS assimilation. Only the correlation is calculated because of the scale difference.

There is a clear benefit from the SMOS soil assimilation even at deeper layers than the ones used for the assimilation directly. The peaks in the period from April to June are strongly reduced and the temporal behavior is in line with the in situ time evolution. The correlation scores are also a good indicator of the improvement brought by the assimilation and it is improved for all the precipitation products. Compared to Fig. 3, the seasonal behavior of the water table depth is much more respected with smoother peaks during the dry season. The statistics performances are summarized in Table 3 for all the options: RT precipitation only, SMOS assimilation using RT forcing, and RE precipitation only. After assimilation, the performances are either even better or equivalent compared to RE simulations.

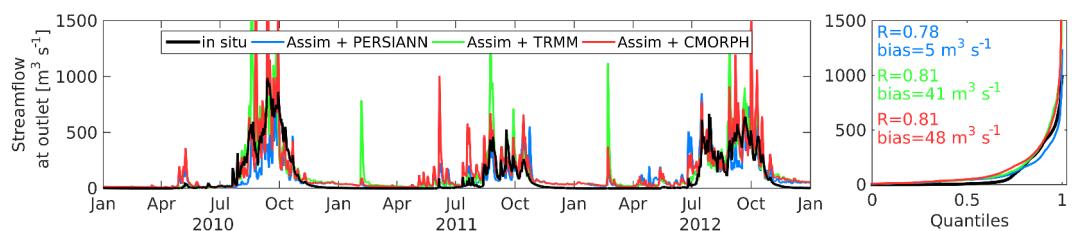
#### 4.3 Impact on the streamflow simulations

Finally, Fig. 8 shows the simulations of the streamflow at the outlet of the basin after assimilation. Compared to the open-loop simulations in Fig. 4, improvements can clearly be identified: the rises are smoother, the dry season is more respected, and the time evolution is much more in line with the in situ observations than using RT precipitation alone. Table 4 shows the statistics of the streamflow simulations using the three satellite products.

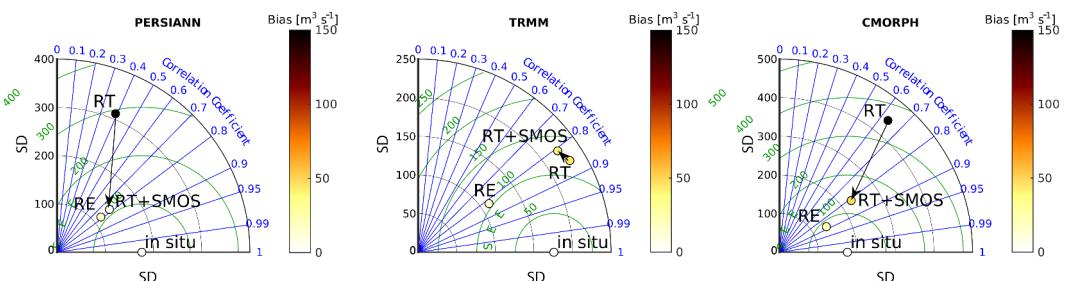
Except for the TRMM product, all the streamflow statistics are improved by the assimilation, especially the error

**Table 4.** Statistics of the simulated streamflow ( $Q$ ) compared to the in situ measurements at the outlet of the basin for 2010–2012. Three cases are considered: open-loop simulations using real-time satellite precipitation (RT), assimilation of SMOS soil moisture with real-time precipitation (RT + SMOS) and open-loop simulation using reanalyzed precipitation (RE). Improvements are indicated in bold font.

$Q$	PERSIANN			TRMM			CMORPH		
	RT	RT + SMOS	RE	RT	RT + SMOS	RE	RT	RT + SMOS	RE
$R$	0.39	<b>0.78</b>	0.78	0.86	0.81	0.82	0.64	<b>0.81</b>	0.88
bias	147.2	<b>4.5</b>	−15.6	44.4	<b>40.9</b>	−15.5	214.6	<b>47.8</b>	−19.9
sdd	292.2	<b>111.2</b>	112.2	120.3	131.4	105.2	356.6	<b>134.2</b>	85.8
RMSE	327.2	<b>111.3</b>	113.3	128.3	137.6	106.3	416.2	<b>142.5</b>	88.0
Nash	−2.45	<b>0.60</b>	0.59	0.47	0.39	0.64	−4.59	<b>0.35</b>	0.75



**Figure 8.** Simulations of the streamflow at the outlet after SMOS soil moisture assimilation with real-time precipitation forcing (indicated in colors for PERSIANN, TRMM and CMORPH) compared to in situ measurements (black line).



**Figure 9.** Taylor diagrams of the streamflow performances for the three rainfall products (PERSIANN on the left, TRMM in the middle, CMORPH on the right) using their real-time version only (RT), their reanalyzed version (RE), and the RT version after SMOS assimilation (RT + SMOS). The arrow shows the changes in the statistics before and after SMOS assimilation.

(divided by 3), and the Nash coefficient (from negative to positive). Even if the reanalyzed precipitation produce better performances, the improvement using SMOS assimilation with RT precipitation is important. The TRMM case is different from the other two products since the RT version already gives fair performances, and the assimilation degrades these performances a little bit, whereas the reanalyzed version slightly improves them.

Another representation of these statistics is the Taylor diagram in Fig. 9. It shows in a more graphical way the improvement brought by the assimilation of SMOS soil moisture products. The in situ circle on the bottom axis represents the point to be reached by the simulations, which would mean that there is a temporal correlation of 1 (blue radial axis on the right), the standard deviation is the same as the in situ (temporal variability, gray circular axis), the standard deviation of the difference between the simulations and the in situ

is null (green semi-circular axis) and the bias would also be null (point circle filled with colors indicated by the color bar on the right for the absolute value of the bias). In other words, the closer to the in situ point, the better.

The arrows on the diagram show the impact of the assimilation on the statistics using RT precipitation. For TRMM, the after-assimilation point is not much closer indicating no clear evidence of improvement from the assimilation. As mentioned before, the TRMM precipitation product already gave the proper amount of water, so SMOS assimilation cannot improve it very much. However, simulations using PERSIANN and CMORPH products are greatly improved by the assimilation attested by the long arrows ending much closer to the RE and in situ points.

## 5 Conclusions

Precipitation forcing is generally the main driver in hydrological models and it is generally not simple nor immediate to collect and distribute in situ measurements in sufficient number and of quality. If in situ precipitation can be used for model calibration, real-time or quasi-real-time applications require forcing and observations quickly in order to react accordingly, such as in the case of a flooding event. Accurate rainfall products from satellite observations are usually reanalyzed data sets available 2 to 3 months after. Although real-time precipitation products are expected to be biased, they are available a few hours to a couple of days after the observations. Three satellite rainfall products have been tested: PERSIANN, TRMM and CMORPH.

The study shows the benefit of the assimilation of the SMOS soil moisture products on three hydrological variables: the soil moisture, the water table depth and the streamflow, which are key variables in the hydrological processes.

By assimilating SMOS soil moisture, the first impacted variables were naturally the soil moisture of the different soil layers of the model. Here, we have showed that, even using a very simplistic methodology of assimilation, the bias in the simulated soil moisture has decreased significantly after the assimilation using the real-time precipitation product. At deeper ground, the simulations of the water table depth showed a much better correlation after the assimilation when compared to in situ measurements (from 0.09–0.70 to 0.82–0.87). These scores were either higher or equivalent to those from the reanalyzed rainfall products. This positive impact of the assimilation on these hydrological variables can lead to a better simulation and management of the actual ground water resources.

The inaccurate amount of water brought by the real-time rainfall products also has a substantial impact on the streamflow. The extra water can saturate the soil faster, thus increase the runoff and the subsurface lateral flow, and be finally intercepted by the water channel. This whole sequence of processes is also positively impacted by the soil moisture assimilation. The streamflow at the outlet of the basin has been much improved for the PERSIANN and CMORPH rainfall products with errors divided by a factor 3 and a Nash coefficient going from negative to positive (TRMM real-time product was already fairly good compared to the other real-time products). After assimilation, the performances were either slightly lower or equivalent to those using the reanalyzed products. Again, this positive impact of the assimilation can lead to a better simulation and management of extreme events such as floods during the monsoon period in this case.

This work shows the possibility to implement a near-real-time hydrologic framework for real-time application wherever it is possible to obtain a proper calibration of the hydrological model beforehand, which is one limitation of this method but this can be overcome by using reanalyzed satel-

lite precipitation. Optionally, the real-time rainfall products could be directly corrected using SMOS observations and following current methodologies (Crow et al., 2011; Pellarin et al., 2013; Brocca et al., 2014; Wanders et al., 2015). Another limitation comes from the choice of the assimilation method. Optimal interpolation relies on assumptions about the error covariances of the model and the observations. In this study, these two matrices have been over-simplified. By implementing ensemble technics, these assumptions could be avoided and the impact of the soil moisture assimilation on the other hydrological variables would be enhanced.

**Acknowledgements.** The authors would like to first thank the Direction Générale de l'Eau du Bénin for the streamflow measurements at the two sub-catchments (Beterou and Cote 238), and the Centre National d'Etudes Spatiales (CNES) TOSCA program for funding this project. The authors would also like to acknowledge the Global Modeling and Assimilation Office (GMAO) and the GES DISC for the dissemination of MERRA data, NOAA and NASA for the dissemination of the precipitation products (PERSIANN, TRMM and CMORPH), the AMMA-CATCH team for providing the in situ measurements, and the ALMIP-2 team for the first DHSVM calibration set. The AMMA-CATCH regional observing system was set up thanks to an incentive funding of the French Ministry of Research that allowed pooling together various pre-existing small-scale observing setups. The continuity and long-term perennity of the measurements have been made possible by uninterrupted IRD funding since 1990 and by continuous CNRS-INSU funding since 2005.

Edited by: F. Fenicia

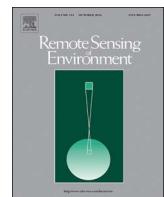
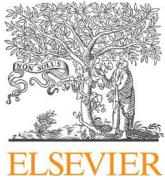
## References

- Bitew, M. M. and Gebremichael, M.: Assessment of satellite rainfall products for streamflow simulation in medium watersheds of the Ethiopian highlands, *Hydrol. Earth Syst. Sci.*, 15, 1147–1155, doi:10.5194/hess-15-1147-2011, 2011.
- Brocca, L., Melone, F., Moramarco, T., Wagner, W., Naeimi, V., Bartalis, Z., and Hasenauer, S.: Improving runoff prediction through the assimilation of the ASCAT soil moisture product, *Hydrol. Earth Syst. Sci.*, 14, 1881–1893, doi:10.5194/hess-14-1881-2010, 2010.
- Brocca, L., Moramarco, T., Melone, F., Wagner, W., Hasenauer, S., and Hahn, S.: Assimilation of surface and root-zone ASCAT soil moisture products into rainfall-runoff modeling, *IEEE T. Geosci. Remote*, 50, 2542–2555, 2012.
- Brocca, L., Ciabatta, L., Massari, C., Moramarco, T., Hahn, S., Hasenauer, S., Kidd, R., Dorigo, W., Wagner, W., and Levizzani, V.: Soil as a natural rain gauge: estimating global rainfall from satellite soil moisture data, *J. Geophys. Res.*, 119, 5128–5141, 2014.
- Casse, C., Gosset, M., Peugeot, C., Pedinotti, V., Boone, A., Tanimoun, B., and Decharme, B.: Potential of satellite rainfall products to predict NIger River flood events in Niamey, *Atmos. Res.*, 163, 162–176, 2015.

- Chakrabarti, S., Bongiovanni, T., Judge, J., Zotarelli, L., and Bayer, C.: Assimilation of SMOS soil moisture for quantifying drought impacts on crop yield in agricultural regions, *IEEE J. Select. Top. Appl. Earth Obs. Rem. S.*, 7, 3867–3879, 2014.
- Crow, W., van den Berg, M., Huffman, G., and Pellarin, T.: Correcting rainfall using satellite-based surface soil moisture retrievals: the Soil Moisture Analysis Rainfall Tool (SMART), *Water Resour. Res.*, 47, W08521, doi:10.1029/2011WR010576, 2011.
- Cuartas, L., Tomasella, J., Nobre, A., Nobre, C., Hodnett, M., Waterloo, M., de Oliveira, S., de Cassia von Randow, R., Trançoso, R., and Ferreira, M.: Distributed hydrological modeling of a micro-scale rainforest watershed in Amazonia: model evaluation and advances in calibration using the new HAND terrain model, *J. Hydrol.*, 462–463, 15–27, 2012.
- Cuo, L., Giambelluca, T., Ziegler, A., and Nullet, M.: Use of the distributed hydrology soil vegetation model to study road effects on hydrological processes in Pang Khum Experimental Watershed, northern Thailand, *Forest Ecol. Manage.*, 224, 81–94, 2006.
- De Lannoy, G., Reichle, R., Houser, P., Arseneault, K., Verhoest, N., and Pauwels, V.: Satellite-scale snow water equivalent assimilation into a high-resolution land surface model, *J. Hydrometeorol.*, 11, 352–369, 2010.
- Draper, C., Reichle, R., De Lannoy, G., and Liu, Q.: Assimilation of passive and active microwave soil moisture retrievals, *Geophys. Res. Lett.*, 39, L04401, doi:10.1029/2011GL050655, 2012.
- Du, E., Link, T., Gravelle, J., and Hubbart, J.: Validation and sensitivity test of the distributed hydrology soil vegetation model (DHSVM) in a forested mountain watershed, *Hydrol. Process.*, 28, 6196–6210, 2014.
- Gascon, T., Vischel, T., Lebel, T., Quantin, G., Pellarin, T., Quatela, V., Leroux, D., and Galle, S.: Influence of rainfall space-time variability over the Ouémé basin in Benin, *P. Int. Assoc. Hydrolog. Sci.*, 368, 102–107, 2015.
- Gaspari, G. and Cohn, S.: Construction of correlation functions in two and three dimensions, *Q. J. Roy. Meteorol. Soc.*, 125, 723–757, 1999.
- Gosset, M., Viarre, J., Quantin, G., and Alcoba, M.: Evaluation of several rainfall products used for hydrological applications over West Africa using two high-resolution gauge networks, *Q. J. Roy. Meteorol. Soc.*, 139, 923–940, 2013.
- Han, E., Merwade, V., and Heathman, G.: Implementation of surface soil moisture data assimilation with watershed scale distributed hydrological model, *J. Hydrol.*, 416, 98–117, 2012.
- Hollmann, R., Merchant, C., Saunders, R., Downy, C., Buchwitz, M., Cazenave, A., Chiavero, E., Defourny, P., de Leeuw, G., Forsberg, R., Holzer-Popp, T., Paul, F., Sandven, S., Sathyendranath, S., van Roozendael, M., and Wagner, W.: The ESA climate change initiative satellite data records for essential climate variables, *B. Am. Meteorol. Soc.*, 94, 1541–1552, 2013.
- Hsu, K., Gao, X., and Sorooshian, S.: Precipitation estimation from remotely sensed information using artificial neural networks, *J. Appl. Meteorol.*, 36, 1176–1190, 1997.
- Huffman, G., Adler, R., Bolvin, D., Gu, G., Nelkin, E., Bowman, K., Hong, Y., Stocker, E., and Wolff, D.: The TRMM multi-satellite precipitation analysis: quasi-global, multi-year, combined-sensor precipitation estimates at fine scale, *J. Hydrometeorol.*, 8, 38–55, 2007.
- Jacquette, E., Al Bitar, A., Mialon, A., Kerr, Y., Quesney, A., Cabot, F., and Richaume, P.: SMOS CATDS level 3 global products over land, *Proceedings of SPIE-The International Society for Optical Engineering, Remote Sensing for Agriculture, Ecosystems, and Hydrology XII*, vol. 7824, article number 78240K, SPIE conference, 20–22 September 2010, Toulouse, France, 2010.
- Joyce, R., Janowiak, J., Arkin, P., and Xie, P.: CMORPH: a method that produces global precipitation estimates from passive microwave and infrared data at high spatial and temporal resolution, *J. Hydrometeorol.*, 5, 487–503, 2004.
- Kerr, Y., Waldteufel, P., Richaume, P., Wigneron, J.-P., Ferrazzoli, P., Mahmoodi, A., Bitar, A. A., Cabot, F., Gruhier, C., Juglea, S., Leroux, D., Mialon, A., and Delwart, S.: The SMOS Soil Moisture Retrieval Algorithm, *IEEE T. Geosci. Remote.*, 50, 1384–1403, 2012.
- Kerr, Y., Waldteufel, P., Richaume, P., Daveport, I., Ferrazzoli, P., and Wigneron, J.-P.: SMOS Level 2 Processor Soil Moisture ATBD, Tech. Rep. SO-TN-ESL-SM-GS-0001, SM-ESL, CBSA, available at: [http://www.cesbio.ups-tlse.fr/SMOS\\_blog/?page\\_id=815](http://www.cesbio.ups-tlse.fr/SMOS_blog/?page_id=815) (last access: July 2016), 2015.
- Khan, S. I., Adhikari, P., Hong, Y., Vergara, H., Adler, R., Pollicelli, F., Irwin, D., Korme, T., and Okello, L.: Hydroclimatology of Lake Victoria region using hydrologic model and satellite remote sensing data, *Hydrol. Earth Syst. Sci.*, 15, 107–117, doi:10.5194/hess-15-107-2011, 2011.
- Kumar, S., Peters-Lidard, C., Mocko, D., Reichle, D., Liu, Y., Arseneault, K., Xia, Y., Ek, M., Riggs, G., Livneh, B., and Cosh, M.: Assimilation of remotely sensed soil moisture and snow depth retrievals for drought estimation, *J. Hydrometeorol.*, 15, 2446–2469, 2014.
- Lebel, T., Cappaerae, B., Galle, S., Hanan, N., Kergoat, L., Levis, S., Vieux, B., Descroix, L., Gosset, M., Mougin, E., Peugeot, C., and Seguis, L.: AMMA-CATCH studies in the Sahelian region of West-Africa: an overview, *J. Hydrol.*, 375, 3–13, 2009.
- Li, X.-H., Zhang, Q., and Xu, C.-Y.: Suitability of the TRMM satellite rainfalls in driving a distributed hydrological model for water balance computations in Xinjiang catchment, Poyang lake basin, *J. Hydrol.*, 426–427, 28–38, 2012.
- Lievens, H., Tomer, S., Al Bitar, A., de Lannoy, G., Drusch, M., Dumedah, G., Hendricks Franssen, H., Kerr, Y., Martens, B., Pan, M., Roundy, J., Vereecken, H., Walker, J., Wood, E., Verhoest, N., and Pauwels, V.: SMOS soil moisture assimilation for improved hydrologic simulation in the Murray Darling basin, Australia, *Remote Sens. Environ.*, 168, 146–162, 2015.
- Liu, Y., Dorigo, W., Parinussa, R., de Jeu, R., Wagner, W., McCabe, M., Evans, J., and van Dijk, A.: Trend-preserving blending of passive and active microwave soil moisture retrievals, *Remote Sens. Environ.*, 123, 280–297, 2012.
- Liu, Y. Y., Parinussa, R. M., Dorigo, W. A., De Jeu, R. A. M., Wagner, W., van Dijk, A. I. J. M., McCabe, M. F., and Evans, J. P.: Developing an improved soil moisture dataset by blending passive and active microwave satellite-based retrievals, *Hydrol. Earth Syst. Sci.*, 15, 425–436, doi:10.5194/hess-15-425-2011, 2011.
- Louvet, S., Pellarin, T., al Bitar, A., Cappaerae, B., Galle, S., Grippo, M., Gruhier, C., Kerr, Y., Lebel, T., Mialon, A., Mougin, E., Quantin, G., Richaume, P., and de Rosnay, P.: SMOS soil moisture product evaluation over West-Africa from local to regional scale, *Remote Sens. Environ.*, 156, 383–394, 2015.
- Nash, J. and Sutcliffe, J.: River flow forecasting through conceptual models 1, a discussion of principles, *J. Hydrol.*, 10, 282–290, 1970.

- Parrens, M., Mahfouf, J.-F., Barbu, A. L., and Calvet, J.-C.: Assimilation of surface soil moisture into a multilayer soil model: design and evaluation at local scale, *Hydrol. Earth Syst. Sci.*, 18, 673–689, doi:10.5194/hess-18-673-2014, 2014.
- Pauwels, V., Hoeben, R., Verhoest, N., and Troch, F. D.: The importance of the spatial patterns of remotely sensed soil moisture in the improvement of discharge predictions for small-scale basins through data assimilation, *J. Hydrol.*, 251, 88–102, 2001.
- Pauwels, V., Hoeben, R., Verhoest, N., Troch, F. D., and Troch, P.: Improvement of TOPLATS-based discharge predictions through assimilation of ERS-based remotely sensed soil moisture values, *Hydrol. Process.*, 16, 995–1013, 2002.
- Pellarin, T., Louvet, S., Gruhier, C., Quantin, G., and Legout, C.: A simple and effective method for correcting soil moisture and precipitation estimates using AMSR-E measurements, *Remote Sens. Environ.*, 136, 28–36, 2013.
- Reichle, R. and Koster, R.: Assessing the impact of horizontal error correlations in background fields on soil moisture estimation, *J. Hydrometeorol.*, 4, 1229–1242, 2003.
- Renzullo, L., van Dijk, A., Perraud, J.-M., Collins, D., Hendreson, B., Jin, H., Smith, A., and McJannet, D.: Continental satellite soil moisture data assimilation improves root-zone moisture analysis for water resources assessment, *J. Hydrol.*, 519, 2747–2762, 2014.
- Ridler, M.-E., Madsen, H., Stisen, S., Bircher, S., and Fensholt, R.: Assimilation of SMOS-derived soil moisture in a fully integrated hydrological and soil-vegetation-atmosphere transfer model in Western Denmark, *Water Resour. Res.*, 50, 8962–8981, 2014.
- Rienecker, M., Suarez, M., Gelaro, R., Todling, R., Bacmeister, J., Liu, E., Bosilovich, M., Schubert, S., Takacs, L., Kim, G.-K., Bloom, S., Chen, J., Collins, D., Conaty, A., Da Silva, A., Gu, W., Joiner, J., Koster, R., Lucchesi, R., Molod, A., Owens, T., Pawson, S., Pegion, P., Redder, C., Reichle, R., Robertson, F., Rudick, A., Sienkiewicz, M., and Woollen, J.: MERRA: NASA's Modern-Era Retrospective Analysis for Research and Applications, *J. Climate*, 24, 3624–3648, 2011.
- Sahoo, A., De Lannoy, G., Reichle, R., and Houser, P.: Assimilation and downscaling of satellite observed soil moisture over the Little River experimental watershed in Georgia, USA, *Adv. Water Resour.*, 52, 19–33, 2013.
- Seguis, L., Kamagate, B., Favreau, G., Descloitres, M., Seidel, J., Galle, S., Peugeot, C., Gossel, M., Le Barbe, L., Malinur, F., Van Exter, S., Arjounin, M., Boubkraoui, S., and Wubda, M.: Origins of streamflow in a crystalline basement catchment in a sub-humid Sudanian zone: The Donga basin (Benin, West Africa) Inter-annual variability of water budget, *J. Hydrol.*, 402, 1–13, 2011.
- Sorooshian, S., Hsu, K., Gao, X., Gupta, H., Imam, B., and Braithwaite, D.: Evaluation of PERSIANN system satellite-based estimates of tropical rainfall, *B. Am. Meteorol. Soc.*, 81, 2035–2046, 2000.
- Thiemig, V., Rojas, R., Zambrano-Bigiarini, M., Levizzani, V., and Roo, A. D.: Validation of satellite-based precipitation products over sparsely gauged African river basins, *J. Hydrometeorol.*, 13, 1760–1783, 2012.
- Vischel, T. and Lebel, T.: Assessing the water balance in the Sahel: impact of small scale rainfall variability on runoff. Part 2: idealized modeling of runoff sensitivity, *J. Hydrol.*, 333, 340–355, 2007.
- Vischel, T., Quantin, G., Lebel, T., Viarre, J., Gosset, M., Cazenave, F., and Panthou, G.: Generation of high-resolution rain fields in West Africa: evaluation of dynamics interpolation methods, *J. Hydrometeorol.*, 12, 1465–1482, 2011.
- Wagner, W., Dorigo, W., de Jeu, R., Fernandez, D., Benveniste, J., Haas, E., and Ertl, M.: Fusion of active and passive microwave observations to create an Essential Climate Variable data record on soil moisture, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences (ISPRS Annals)*, I-7, XXII ISPRS Congress, Melbourne, Australia, 315–321, 2012.
- Wanders, N., Karsenberg, D., de Roo, A., de Jong, S. M., and Bierkens, M. F. P.: The suitability of remotely sensed soil moisture for improving operational flood forecasting, *Hydrol. Earth Syst. Sci.*, 18, 2343–2357, doi:10.5194/hess-18-2343-2014, 2014.
- Wanders, N., Pan, M., and Wood, E.: Correction of real-time satellite precipitation with multi-sensor satellite observations of land surface variables, *Remote Sens. Environ.*, 160, 206–221, 2015.
- Ward, E., Buytaert, W., Peaver, L., and Wheater, H.: Evaluation of precipitation products over complex mountainous terrain: a water resources perspective, *Adv. Water Resour.*, 34, 1222–1231, 2011.
- Whitaker, A., Alila, Y., Beckers, J., and Toews, D.: Application of the Distributed Hydrology Soil Vegetation Model to Redfish Creek, British Columbia: model evaluation using internal catchment data, *Hydrol. Process.*, 17, 199–224, 2003.
- Wigmsta, M., Vail, L., and Lettemaier, D.: A distributed hydrology-vegetation model for complex terrain, *Water Resour. Res.*, 30, 1665–1679, 1994.
- Yilmaz, M. and Crow, W.: The optimality of potential rescaling approaches in land data assimilation, *J. Hydrometeorol.*, 14, 650–660, 2013.

**F.1.3 Román-Cascón et al. 2017 : Correcting satellite-based precipitation products through SMOS soil moisture data assimilation in two land-surface models of different complexity : API and SURFEX**



## Correcting satellite-based precipitation products through SMOS soil moisture data assimilation in two land-surface models of different complexity: API and SURFEX

Carlos Román-Cascón<sup>a,\*</sup>, Thierry Pellarin<sup>a</sup>, François Gibon<sup>a</sup>, Luca Brocca<sup>c</sup>, Emmanuel Cosme<sup>a</sup>, Wade Crow<sup>d</sup>, Diego Fernández-Prieto<sup>e</sup>, Yann H. Kerr<sup>b</sup>, Christian Massari<sup>c</sup>

<sup>a</sup> Univ. Grenoble Alpes, CNRS, IRD, Grenoble INP, IGE, Grenoble F-38000, France

<sup>b</sup> Centre d'Etudes Spatiales de la Biosphère (CESBIO), Université Toulouse 3 CNES CNRS IRD, Toulouse, France

<sup>c</sup> National Research Council CNR, Research Institute for Geo-Hydrological Protection, Perugia, Italy

<sup>d</sup> Hydrology and Remote Sensing Laboratory, USDA Agricultural Research Service, Beltsville, MD, USA

<sup>e</sup> European Space Agency (ESA), Frascati, Italy



### ARTICLE INFO

**Keywords:**

Rainfall  
Soil moisture  
SMOS  
API  
SURFEX  
Particle filter

### ABSTRACT

Global rainfall information is useful for many applications. However, real-time versions of satellite-based rainfall products are known to contain errors. Recent studies have demonstrated how the information about rainfall intrinsically contained in soil moisture data can be utilised for improving rainfall estimates. That is, soil moisture dynamics are impacted for several days by the accumulated amount of rainfall following within a particular event. In this context, soil moisture data from the Soil Moisture Ocean Salinity (SMOS) satellite is used in this study to correct rainfall accumulation estimates provided by satellite-based real-time precipitation products such as CMORPH, TRMM-3B42RT or PERSIANN. An algorithm based on the SMOS measurements data assimilation is tested in two land-surface models of different complexity: a simple hydrological model (Antecedent Precipitation Index (API)) and a more sophisticated state-of-the-art land-surface model (SURFEX (*Surface Externalisé*)). We show how the assimilation technique, based on a particle filter method, generally leads to a significant improvement in rainfall estimates, with slightly better results for the simpler (and less computationally demanding) API model. This methodology has been evaluated for six years at ten sites around the world with different land use and climatological features. The results also show the limitations of the methodology in regions highly affected by mountainous terrain, forest or intense radio-frequency interference (RFI), which can notably affect the quality of the retrievals. The satisfactory results shown here invite the future operational application of the methodology in near-real time on a global scale.

### 1. Introduction

Precipitation is a key variable of the water cycle, whose estimation is crucial for many applications (Brocca et al., 2016). Accurate estimates of the amount of water which reaches the ground at specific areas in near-real time are needed for hydrological applications, including flood (Wake, 2013; Jongman et al., 2014; Casse et al., 2015; Lievens et al., 2015) or landslide (Van Asch et al., 1999; Guzzetti et al., 2007; Iverson, 2000; Pennington et al., 2014) emergency response planning. Rainfall accumulation estimates are also very important for agricultural strategy and modelling (Fisher, 1925; French and Schultz, 1984; Akponikpe et al., 2011; Ramarohetra et al., 2013). Besides, accurate precipitation data is certainly decisive for data assimilation in

numerical weather prediction models, since it highly affects surface energy fluxes that will drive the evolution of the planetary boundary layer (Pielke et al., 1998) which is linked to the formation of mesoscale and/or synoptic weather systems. Finally, the link between the spatio-temporal distribution of precipitation and the freshwater availability at several regions of the Earth is crucial for decision-making to mitigate extreme situations (Hou et al., 2014; Shannon et al., 2008), such as intense droughts.

Rain gauges provide the most accurate and reliable data to obtain the amount of rainfall at a point on the Earth's surface (Lanza and Vuerich, 2009). However, the heterogeneous (temporal and spatial) characteristic of rainfall makes the use of the information provided by one (or a few) station(s) not sufficient to address the large-scale

\* Corresponding author.

E-mail address: [carlos.roman-cascon@univ-grenoble-alpes.fr](mailto:carlos.roman-cascon@univ-grenoble-alpes.fr) (C. Román-Cascón).

applications listed above. Therefore, very extensive deployment of rain gauges is needed to appropriately quantify rainfall accumulation over relatively-large areas using spatial analysis techniques (Creutin and Obled, 1982; Jones et al., 2009). This is possible in some areas of economically developed countries, such as in the United States (e.g. Allen and Naney, 1991) or France (e.g. Delrieu et al., 2004). However, in developing regions (especially those in Africa), the number of available rain gauges has decreased over the last two decades (Ali and Lebel, 2009), mainly due to maintenance costs or political unrest. In order to improve the spatial coverage of rainfall information in areas with a limited number of rain gauges, the complementary use of ground-based weather radar data is a very useful technique. However, weather radars suffer from many issues that affect the reliability of the estimates (Krajewski and Smith, 2002) and are not available everywhere in the world.

To address these issues, important efforts have devoted during the last few years to develop and improve precipitation estimates from satellites (Ebert et al., 2007). These satellite-based precipitation products (SPPs) are based on the use of infrared (IR) sensors on-board geostationary satellites and/or microwave (MW) sensors on polar satellites. IR sensors use cloud-top temperatures to indirectly infer the associated precipitation and have the advantage of a larger spatial and denser temporal coverage, but they suffer from accuracy and false-alarm issues due to the indirect retrieval of precipitation (which is not always in accordance with the brightness temperature of the cloud top). MW sensors are more accurate, since they are based on the direct signal of hydrometeors (rain, drizzle, snow or haze) falling from the cloud base, but they have a significantly lower spatio-temporal resolution (Pellarin et al., 2013). To solve this issue, information provided by IR sensors is combined with MW sensors to generate improved multi-sensor SPP. However, even using this combination, several studies have demonstrated how precipitation from these products is biased when compared to real (and spatially averaged) values observed at ground level (e.g. Prasetya et al., 2013; Cai et al., 2015). These issues can be addressed in a post-processing step by correcting the real-time SPP data with ground-based observations, such as for example in the Global Precipitation Climatology Project (GPCP) (Huffman et al., 1997; Adler et al., 2003). However, due to lags in the availability of rain gauges observations, these adjusted products are available only after several days (or even several weeks/months). Moreover, even the adjusted products can be inaccurate in some cases (e.g. Yin and Gruber, 2010).

In this context, the use of near real-time soil moisture retrieved from satellites has been demonstrated as a very promising tool to improve precipitation estimates (Pellarin et al., 2008; Brocca et al., 2013). Soil moisture has the advantage of having a useful memory of rainfall events occurring several days in the past (Seneviratne et al., 2006; McColl et al., 2017). Hence, several studies have recently used this relation with the aim of improving precipitation estimates using different methodologies. Crow and Bolten (2007) used a Kalman filter for the assimilation of soil moisture data from the Advanced Microwave Scanning Radiometer - Earth Observing Systems (AMSR-E) within an Antecedent Precipitation Index (API) model, in order to estimate errors of different SPPs in the Southern United States. Pellarin et al. (2008) also used soil moisture data from AMSR-E to remove erroneous rain events from an IR satellite sensor using the API model. Almost simultaneously, Crow et al. (2009) used a conceptually similar approach to directly correct rainfall events of several SPPs and, later, Crow et al. (2011) improved their assimilation and modelling techniques to create the Soil Moisture Analysis Rainfall Tool (SMART). A similar methodology was applied in Wanders et al. (2015), by using a particle-filter assimilation technique for correcting precipitation over the US. In a different approach, Brocca et al. (2013) and Brocca et al. (2014) used satellite soil moisture data to directly infer rainfall quantities by inverting the soil-water balance equation via the so-called SM2RAIN methodology. SMART, SM2RAIN and the API-based methodologies were recently tested in Australia in the study of Brocca et al. (2016),

where soil moisture data from the Soil Moisture and Ocean Salinity (SMOS) satellite was used to correct the real-time Tropical Rainfall Measuring Mission (TRMM) Multi-satellite Precipitation Analysis (TMPA) product.

In the present study, a particle-filter (DeChant and Moradkhani, 2011; Yan et al., 2015) assimilation technique, similar - but not identical - to the one applied by Wanders et al. (2015) is applied in two models of different complexity: an API model (an improved version of the one presented in Pellarin et al. (2008)) and the more complex *Surface Externalisée* (SURFEX) land-surface model (Masson et al., 2013). To our knowledge, this is the first time that a complex state-of-the-art land-surface model is compared to a simple one for the aim of correcting rainfall by assimilating satellite soil moisture data. It is hypothesised that the use of a more complex model would improve upon the API model in some conditions (e.g., under large run-off after intense rain events or in dense-vegetated areas highly affected by evapotranspiration). The results provided by using these two models are evaluated in terms of correction for three different real-time SPPs over ten sites around the world with different land cover and climate features (e.g., surface and vegetation characteristics, rainfall climatology, latitude, and closeness to mountainous areas). Past correlation approaches were typically tested in only a few specific locations or regions (e.g. in Australia, US and/or West Africa). In this work, reliable and extensive ground-based precipitation datasets from rain gauges are available at ten diverse sites, providing an excellent framework to test the methodology under different conditions and therefore strengthen the final conclusion of a potential real-time application at ungauged locations worldwide.

The paper is organised as follows: Section 2 details the data used, the API and SURFEX models and the particle filter assimilation technique. Results are presented in Section 3 and the discussion of these results is provided in Section 4. Finally, the main conclusions are summarised in Section 5.

## 2. Data, models and methodology

This section is divided in three main parts. The observational data needed to perform this work are described in the first one. The second part provides a brief description of the two land surface models used and compared in this study. In the third part, the land-surface model assimilation algorithm (LMAA) is described with equations, references and an example figure.

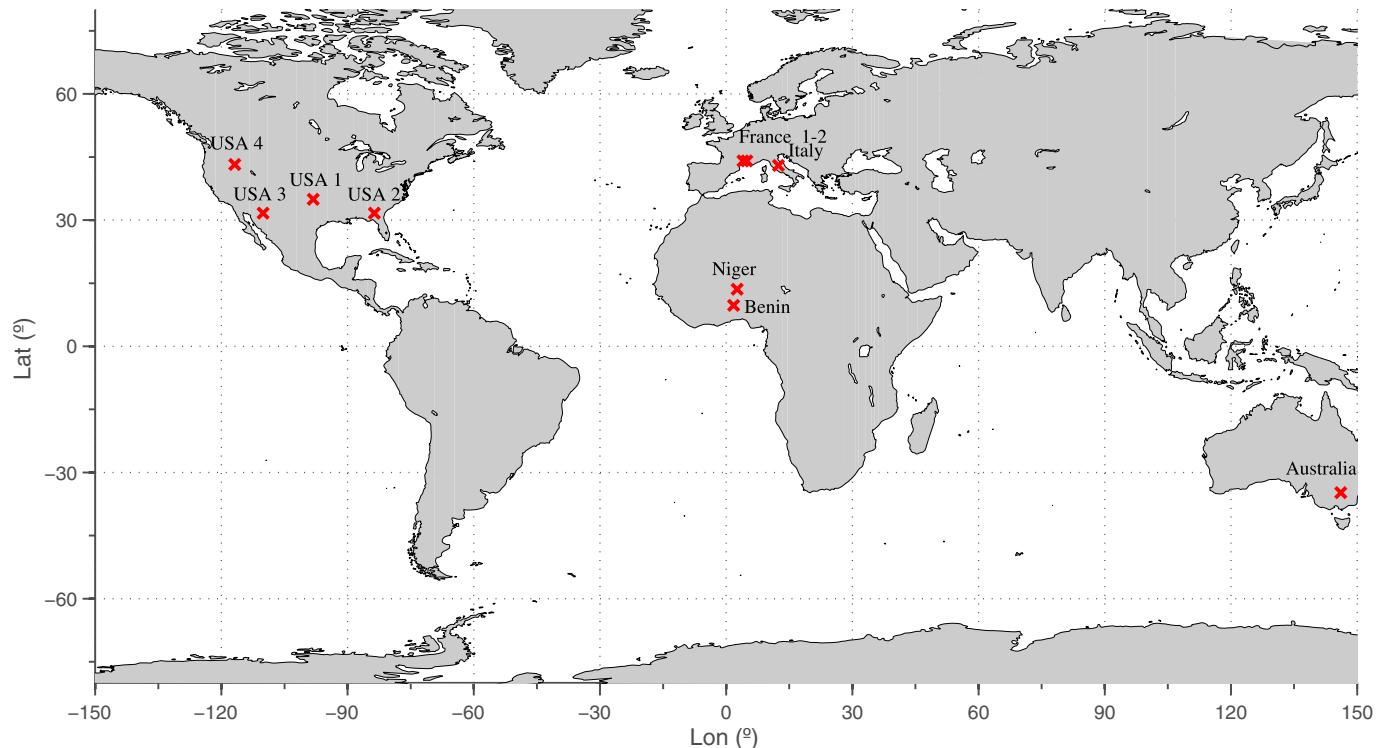
### 2.1. Observational data

This study aims at improving precipitation estimates by using SMOS soil moisture retrievals combined with data from a SPP (the correction is tested for three different ones). Spatially-averaged *in situ* rainfall data from different hydrological networks are used as the reference for the evaluation of the methodology at ten sites around the world. Some additional data were also needed to initialize or to force the land-surface models. All these datasets are explained in the following subsections.

#### 2.1.1. Satellite-based precipitation products (SPPs)

Three different satellite-based precipitation products are used: 1) The Climate Prediction Center morphing method (CMORPH) product (Joyce et al., 2004), 2) the Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks (PERSIANN) product (Sorooshian et al., 2000), and 3) the TRMM-3B42RT from the Tropical Rainfall Measuring Mission real-time product (Huffman et al., 2010).

All of these products combine information from IR and MW sensors to estimate precipitation accumulation with a resolution of 3 h and 0.25°. Due to the spatial mismatch between the grid of these rainfall products and the SMOS grid, the SPP pixels which are closest to the



**Fig. 1.** Location of the ten sites used for the evaluation.

respective SMOS pixel (comparing the centre points) are selected to combine both data in the assimilation procedure. The climatology (6-years from 2010 to 2015) of the adjusted versions of CMORPH and TRMM-3B42 are also used to calculate the parameters needed to rescale the SMOS data (see below for details). These adjusted versions use information from other sources (rain gauges) to improve the first estimation given by their respective real-time versions in a posterior step.

#### 2.1.2. Soil moisture from SMOS

The methodology used to correct the rainfall from the real-time version of the selected SPP is based on the assimilation of soil moisture data from the SMOS satellite. This satellite was launched by the European Space Agency (ESA) in 2009 with the main objective of measuring soil moisture between 0 and 5 cm soil depth and ocean salinity at the sea surface with unprecedented accuracy with an horizontal resolution of  $25 \times 25$  km. The radiometer of this polar-orbiting satellite is composed of 69 antennas in 3 arms, measuring brightness temperatures at 1.417 GHz (L band), with a 19 MHz bandwidth. This range of frequencies is protected from anthropogenic emission, minimally affected by the atmosphere and very sensitive to changes in the soil moisture content of the ground (Kerr et al., 2012). In this work, the level-3 RE04 SMOS dataset provided by CATDS (*Centre Aval de Traitement des Données SMOS*) from 2010 to the end of 2015 is used for the SMOS pixels corresponding to the study area. Soil moisture estimates from SMOS are affected by the accuracy of the retrieval, being lower in complex/mountainous terrain, due to the effect of the different topographic slopes at the surface. L-band emission is also affected by changes in brightness temperatures generated by vegetation, which reduce the accuracy of the retrieval in areas covered by very dense vegetation. In general SMOS multi-angular measurements enables accounting for vegetation contribution to the signal. In addition, SMOS estimates can be significantly affected by anthropogenic emissions in the protected L-band, especially emitted by civil or military services in some areas of the World. The CATDS-SMOS dataset includes different quality indexes, which are useful to estimate the quality of this soil moisture data. In this work, three of these quality indexes were used: 1)

dqx, which is related to the radiometric uncertainty of the measure, 2) RFI fraction, which reflects the estimates contamination by radio frequency interferences, and 3) Chi2, which represents a measure of the quality of the retrieval fit between observed and modelled brightness temperatures (Kerr et al., 2012). These quality indexes are used in this work to determine the quality of each SMOS measurement, but before, all SMOS data with dqx, RFI or Chi2 above respectively 0.045, 0.45 and 3.5 are filtered and not used.

Soil moisture time series from SMOS have systematic differences relative to soil moisture simulated by the two models used in this work. Therefore, a pre-processing step is needed to remove these differences before the application of the assimilation procedure (Plaza et al., 2012). Therefore, all SMOS data have been re-scaled using a Cumulative Distribution Function (CDF) matching procedure (Brocca et al., 2011), in order to remove the systematic bias between SMOS and model time series. Although this technique is not the optimal solution (Yilmaz and Crow, 2013), it has been widely used in similar studies and it is convenient when the model error and the satellite data errors are not well known and can be variable between sites. The parameters used from the CDF matching re-scaling procedure in Brocca et al. (2011) have been obtained using 6 years (from 2010 to 2015) of soil moisture simulated by each model when forced with the adjusted (i.e., non-real-time) version of the SPP (CMORPH and TRMM-3B42). These parameters have been applied to the SMOS time series before the assimilation. Following this strategy, the same parameters could be used for an operational application. Besides, these parameters can be easily obtained in all the pixels at the global scale. Since the adjusted version of PERSIANN does not exist from 2011 onwards, the coefficients for SMOS rescaling when correcting this product have been obtained with the adjusted version of TRMM-3B42 product. As it will be shown later, in this case, the use of an independent product (TRMM-3B42 adjusted) for the parameters calculation when correcting a real-time product (PERSIANN) also provides very good results, suggesting that independent products (e.g. GPCP) could be also used for the calculation of the CDF-matching parameters with satisfactory performance.

**Table 1**

Information of 10 sites used in this study. Coordinates indicate the centre of the SMOS pixel. The number of rain gauges within the SMOS pixel and averaging technique are included in the last column.

Name	Site and coordinates	Climate and mean annual rainfall (mm)	Land cover/topography/RFI	Nº of rain gauges/averaging
Niger	SW of Niger 13.56°N/2.72°E	Semi-arid (509)	Semi-arid vegetation/ flat/no RFI	5 kriging
Benin	Central Benin 9.76°N/1.69°E	Sub-humid (1267)	Wooded savannah, crops/ flat/no RFI	10 kriging
Australia	Yanco 34.70°S/146.15°E	Semi-arid to template (420)	Crop, grazing/ flat/no RFI	4 arithmetic mean
USA 1	Little Washita 34.93°N/98.17°W	Sub-humid (797)	Range, wheat/ rolling/no RFI	20 kriging
USA 2	Little River 31.66°N/83.64°W	Humid (1095)	Row crop, forest/ flat/no RFI	12 kriging
USA 3	Walnut Gulch 31.66°N/110.10°W	Semi-arid (229)	Range/ rolling/no RFI	88 kriging
USA 4	Reynolds Creek 43.24°N/116.84°W	Semi-arid (472)	Range/ mountainous/no RFI	26 kriging
Italy	Umbria 42.97°N/12.32°E	Mediterranean (872)	Woods, crops/ rolling/RFI yes	6 arithmetic mean
France 1	Anduze 44.05°N/4.20°E	Mediterranean (1207)	Range, crop, urban, forest/ rolling/RFI yes	5 kriging
France 2	Saint Joseph 44.05°N/4.80°E	Mediterranean (745)	Range, crop, urban, forest/ mountainous/RFI yes	7 kriging

### 2.1.3. In situ precipitation data

*In situ* precipitation data from ten different sites around the world (Fig. 1) are considered as the reference data and used to evaluate LMAA methodology. These sites exhibit a wide range of different land covers and climatological characteristics (Table 1) and have the advantage of being extensively instrumented with numerous quality-controlled rain gauges. In addition, some of these sites have been intentionally chosen because they capture features that could limit the potential of the methodology (high RFI, mountainous terrain or high vegetation density, see Table 1).

The *in situ* data was averaged following a kriging procedure at all the sites with high availability of rain gauges in an extensive area surrounding the SMOS pixel ( $25 \times 25$  km). At the Italy and Australia sites, not enough reliable rain gauges were available around the SMOS pixel to apply kriging. Instead, an arithmetic mean was calculated with all the available stations within the SMOS pixel (6 in Italy and 4 in Australia (Smith et al., 2012)). All the data are available at the ten sites for 6 years (from 2010 to 2015) except for USA 4, where there is no data for years 2014 and 2015.

Additionally, *in situ* soil moisture measurements from different soil moisture probes are used in Section 4.3 to analyse which land surface model better captures observed soil moisture dynamics. These instruments belong to the same hydrological networks as the rainfall datasets.

### 2.1.4. Additional forcing and static data

A range of atmospheric variables (2-m air temperature, 2-m specific humidity, long-wave radiation, short-wave radiation, 10-m wind speed, wind direction and surface pressure) acquired from the Modern-ERA Retrospective Analysis for Research and Applications Version 2 (MERRA-2, Bosilovich et al., 2016) are also used in this work to force the SURFEX model. The 2-m air temperature data are used in the API model to take into account the effect of this variable in the exponential decrease of the soil moisture, related to the different rate of evapotranspiration (i.e., higher air temperature will lead to a more rapid decrease of the surface soil moisture).

Soil type and land use information represent static inputs for the SURFEX model. This information is taken from the ECOCLIMAP dataset (Champeaux et al., 2005), which provides global information of the land cover with a resolution of 1 km.

### 2.2. Land-surface models

In this section, the two land-surface models used in this study are briefly explained (API and SURFEX). It should be noted that their large differences in complexity cause important differences in the computational time required by each model, which is a factor to take into account if there is an intention to apply each methodology globally.

#### 2.2.1. API

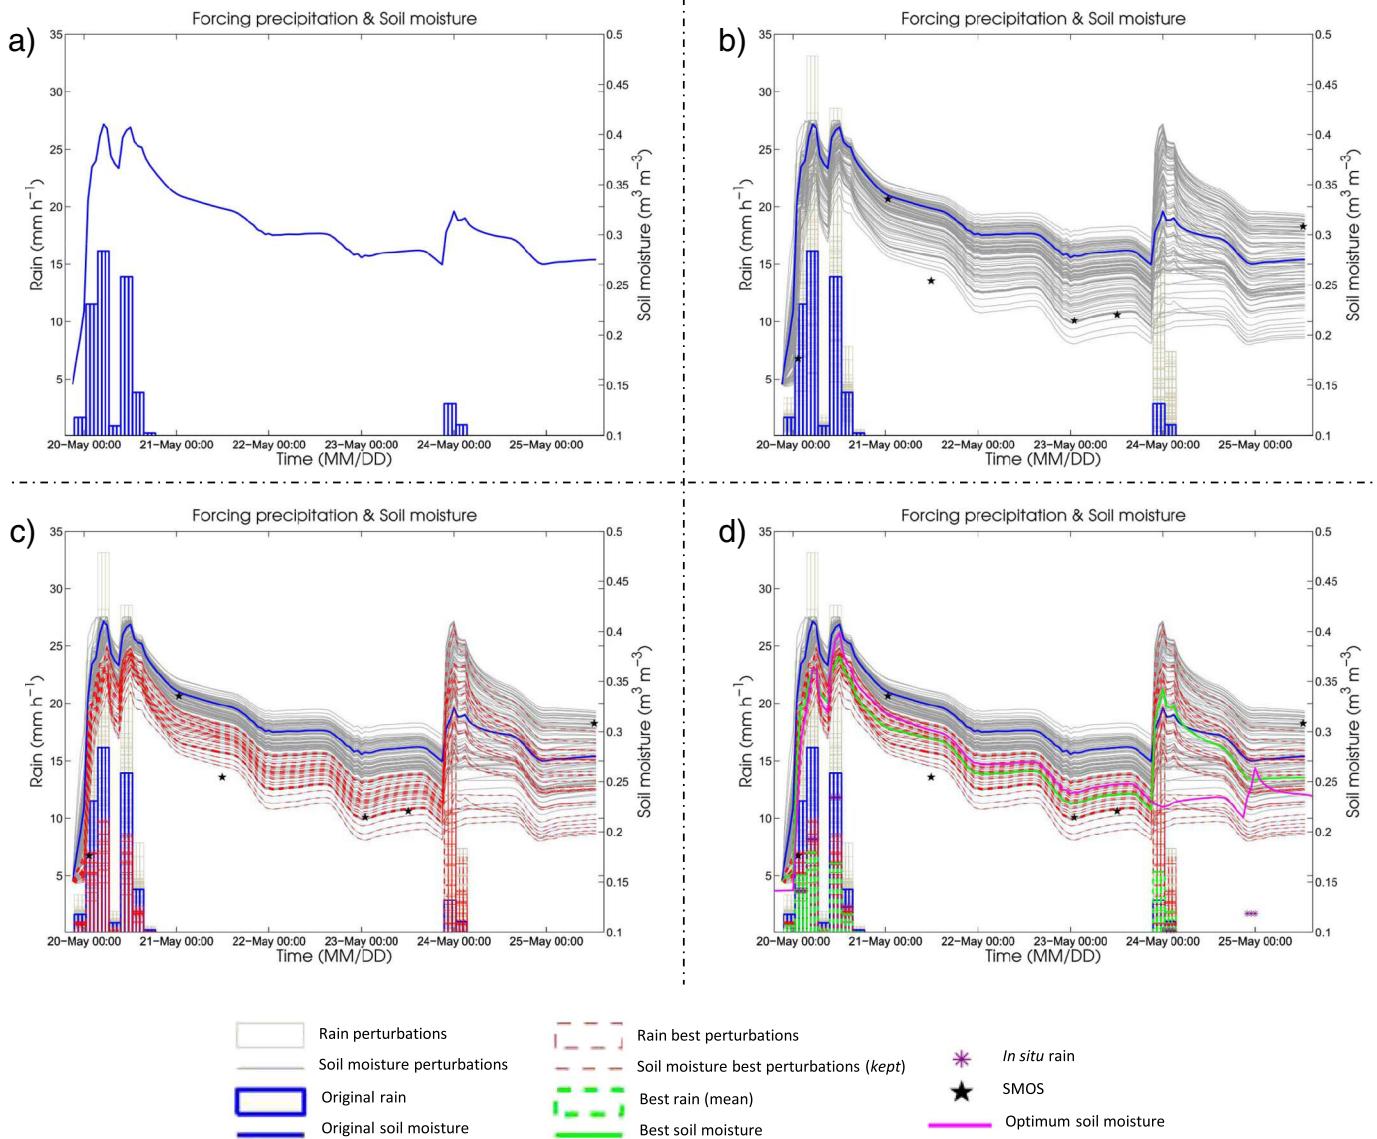
The Antecedent Precipitation Index (API) model used in this work is a modification of the one used in Pellarin et al. (2009) and Brocca et al. (2016). The API model simulates the soil moisture in a thin layer close to the surface using only the previous (antecedent) value of soil moisture and the amount of incident rainfall. In this version of the model (Eq. (1)), the exponential decrease of the soil moisture slightly depends on the air temperature, but there is no dependency on the soil type:

$$sm_{(t)} = [sm_{(t-1)}e^{-\Delta t/\tau}] + [\Theta_{sat} - sm_{(t-1)}][1 - e^{-P_{(t)}/h}], \quad (1)$$

where  $sm_{(t)}$  is the modelled soil moisture for each time step ( $\Delta t$ , 1 h in this study), which depends on two different terms. The first term represents the exponential decrease of the soil moisture with time, based on the previous soil moisture value ( $sm_{(t-1)}$ ) and on  $\tau$ , which modifies the exponential decrease of  $sm_{(t)}$  depending on the air temperature following Eq. (2).  $\tau$  represents the main modification from the versions in Pellarin et al. (2009) and Brocca et al. (2016). Eq. (2) has been derived experimentally in an independent study using air temperature and *in situ* soil moisture probes:

$$\tau = (-7e^{-5}T^4) + (0.006T^3) - (0.03T^2) - (9.5T) + 287, \quad (2)$$

where  $T$  is the air temperature (in this study approximated by the temperature (°C) at 2 m above ground level from MERRA-2 dataset, smoothed on 25 days). This approach allows for the global application of the methodology based on knowledge of the air temperature and without necessity of soil type information for the calibration of  $\tau$ . The second term in Eq. (1) represents the potential increase of soil moisture due to the new rain accumulated at time  $t$ . This possible increase of soil moisture depends on the hourly rainfall ( $P$  in mm/h) and in the saturation parameter ( $\Theta_{sat}$ ), which is the difference between the soil moisture saturation value (fixed to  $0.45 \text{ m}^3 \text{ m}^{-3}$ ) and the precedent value of this variable ( $sm_{(t-1)}$ ).  $h$  is the depth of the soil layer, fixed to 35 mm, which is similar to the sensing depth of SMOS observations.



**Fig. 2.** Graphical representation of LMAA method. The figures show an illustrative and real example for USA 1 site in 2011, from 20 May to 25 May. a) Original rainfall (blue bars) from the SPP to be corrected (CMORPH in this example) and its associated soil moisture (blue line) simulated by the model (SURFEX in this example). b) Including 100 simulations with artificially modified rainfall data (grey bars) and their associated soil moisture (grey lines). c) As in b but including in red the 30 soil moisture time series with the lowest RMSE compared to SMOS (*kept*) (the associated rainfall bars are marked in red). d) As in c but with the mean value of red-marked rainfall (green bar) and its associated soil moisture (green line). The green bar is considered as the corrected rainfall, i.e., the final LMAA product. The *in situ* rainfall (reference) is shown with purple stars, as well as the soil moisture obtained when the model is forced with this rainfall (purple line), for reference. (For interpretation of the references to colour in this figure legend, the reader is referred to the web version of this article.)

### 2.2.2. SURFEX

SURFEX (*SURface EXternalisée*) is a platform developed by Meteo France and the scientific community to model soil-atmosphere processes. It is composed of different physical models for different surfaces: *nature, urban, ocean and lakes*. Here, we focus on the use of the physical model representing the interactions between soil, vegetation and atmosphere over natural surfaces, which is the *Interaction Sol-Biosphère Atmosphère* (ISBA) land-surface model, developed by CNRM-GAME.

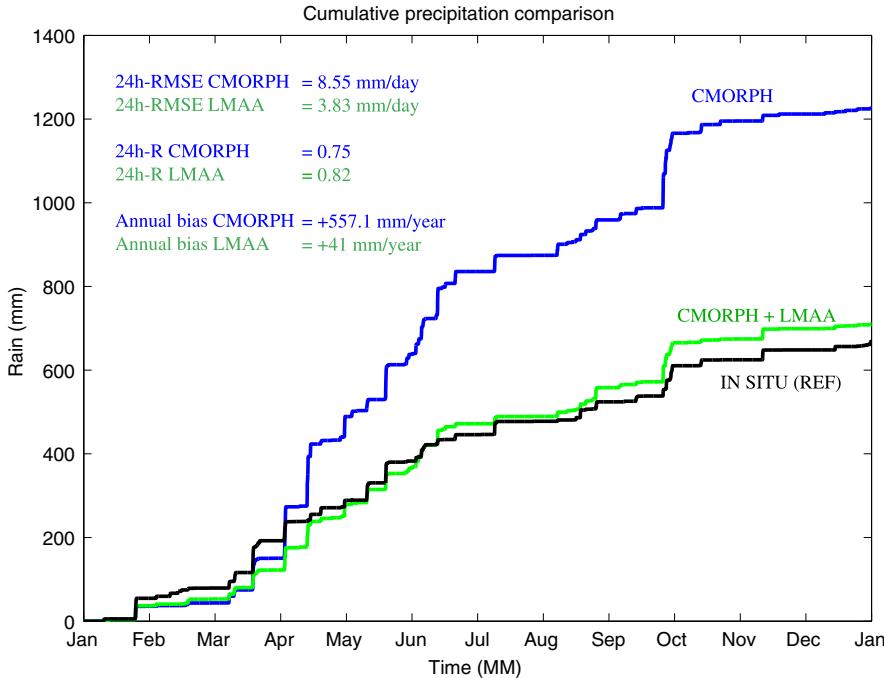
One of the numerous outputs of the ISBA model is the soil moisture. It is simulated for different sub-definition of tiles within the natural surfaces. In this work, the model has been configured with 3 of these sub-definitions for natural surfaces: bare soil, low vegetation and high vegetation (forest). Thus, the model simulates a different evolution of the soil moisture depending on the tile. After different sensitivity experiments (not shown here), we decided to use the low vegetation tile to apply the assimilation technique, since in general it provided the best results for most of the sites. SURFEX is a multi-layer model and,

therefore, it simulates the diffusion of temperature and humidity between adjacent layers, providing different values at different depths. In this work, we use the two first layers of the models (from 0 to 1 cm and from 1 to 4 cm) and we apply a weighted average to these two values, which represents the depth most similar to the SMOS data. As commented above, the model is forced with the SPP-based rainfall (which we aim to correct via the assimilation process) and atmospheric and static forcing datasets, obtained from MERRA-2 and ECOCLIMAP.

### 2.3. Land-surface model assimilation algorithm (LMAA)

The land-surface model assimilation algorithm (LMAA) is based on the application of a particle filter (PF) assimilation method in the two models previously described. For a mathematical or formal description of PF, the reader is referred to Yan et al. (2015).

All the parameters, threshold values and specifications of the methodology here presented have been chosen following comparison of



**Fig. 3.** Example of one of the results of LMAA (with SURFEX) applied to CMORPH real-time product, shown with cumulative rainfall during year 2012 at USA 1 site. CMORPH is shown in blue, *in situ* in black and the corrected amount obtained after the application of LMAA is shown in green. The differences between 24h-RMSE (mm/day), 24h-Pearson correlation and annual cumulative error (mm/year) are indicated with text. (For interpretation of the references to colour in this figure legend, the reader is referred to the web version of this article.)

numerous sensitivity experiments (not shown). Among these experiments, we tested: 1) The choice of the multiplicative factor applied to every SPP rain value ( $k$ , see Eq. (3)), which is especially important in cases of large rain events, as it will be discussed later; 2) The best CDF-matching procedure (see discussion in Section 2.1.2); 3) The length and the number of SMOS data within each assimilated sub-period, which needs to have a trade-off between time distance to the rain event and large enough number of SMOS acquisitions. For values ranging between 4 and 7 SMOS acquisitions reasonable results were obtained. Less of 4 acquisitions can lead to degradation in terms of results, since more SMOS samples are necessary to compensate the possible uncertainties of individual SMOS data (we obtained the best results with 6 SMOS acquisitions); 4) The number of the ensemble of simulations (we tested 100, 200 and 300 with very similar results and selected 100 to limit computation cost); 5) The number of best simulations used to calculate the main rainfall (*kept*), see synthetic experiments in Section 4.4; 6) The threshold values of dqx, RFI and Chi2 for filtering SMOS data (see also discussion in Section 2.1.2), looking for a trade-off between number of SMOS acquisitions and data quality; 7) The suitability or not of smoothing SMOS (finally not appropriate for LMAA because of the loss of rainfall information). Additionally, other more technical experiments were performed for the different models, especially for SURFEX (for example regarding the depth of the layers used and the most appropriate sub-definition of tile to be used, see discussion in Section 2.2.2).

This technical configuration is not the most appropriate for certain specific sites (i.e., a different and more optimal configuration exists for some specific sites). However, we have selected the configuration which offered the best possible general rainfall correction based on the results obtained at the ten sites. Therefore, the same configuration could be applied for every pixel at the worldwide scale without necessity of specifying differences between contrasting areas.

Hereinafter, the procedure applied in our case is briefly explained as follows (see also Fig. 2):

1. The model (API or SURFEX) is initially forced with the SPP that we aim to correct (original rainfall, blue bars in Fig. 2a). The assimilation window (period) is defined by 6 SMOS acquisitions in a maximum of 9 days, i.e., if there are not 6 SMOS acquisitions in 9 days, the maximum possible number of SMOS in that period will

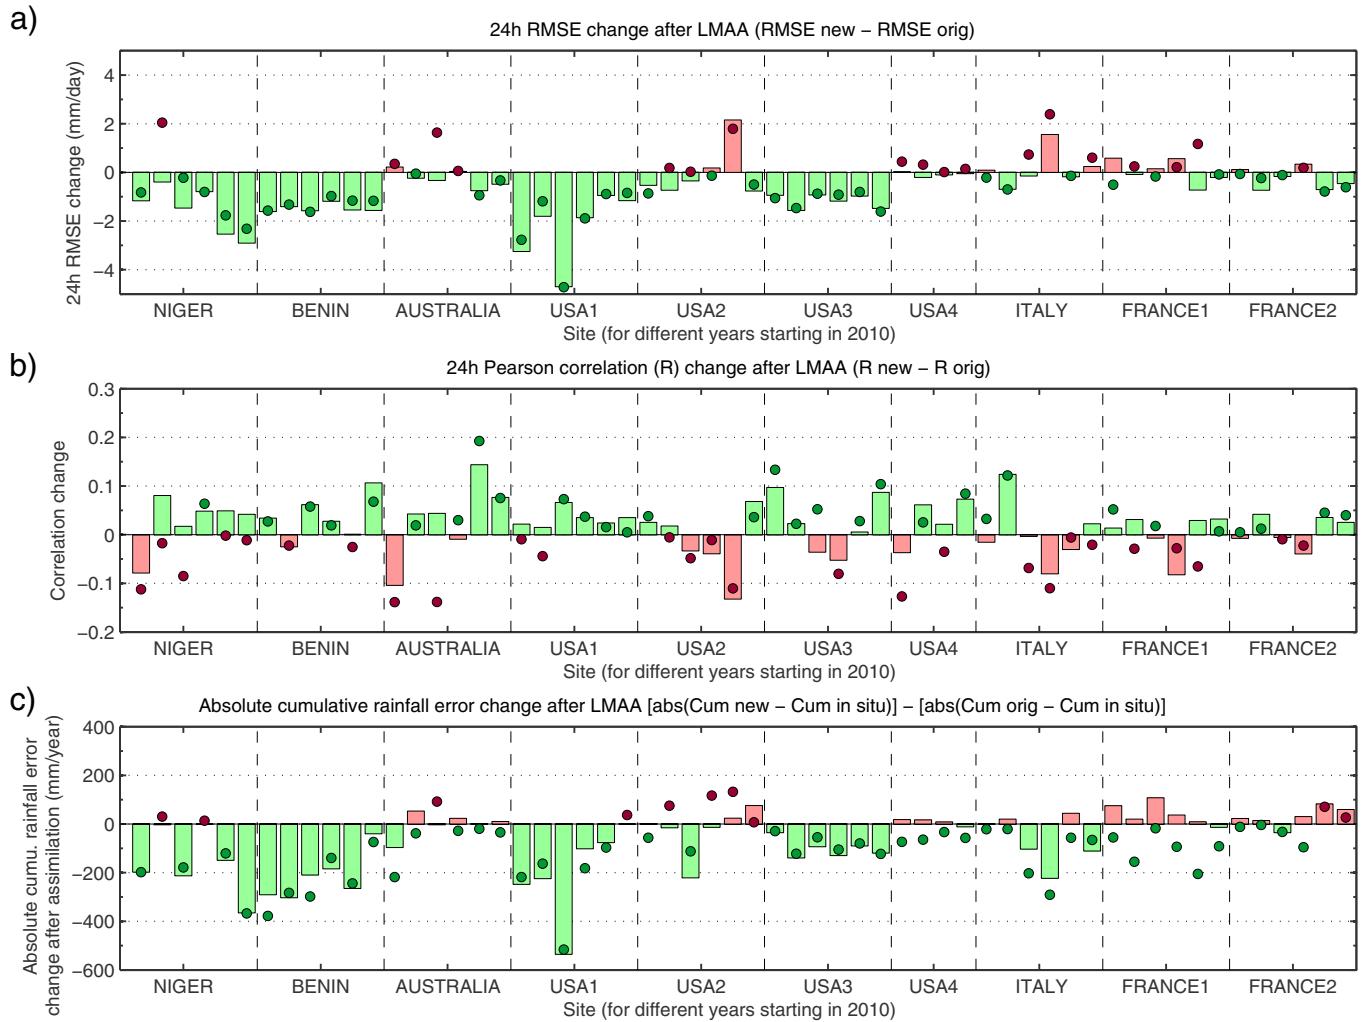
be used (most appropriate numbers obtained after sensitivity experiments, not shown). The blue line in Fig. 2a represents the soil moisture simulated by the model forced with this original rainfall.

2. The original rainfall is modified 100 times (number tested in sensitivity experiments). This new artificial rainfall is used to force the model in 100 new simulations, obtaining an ensemble of predictions (i.e., 100 soil moisture possibilities associated to 100 different rainfall time series). For the modification of rainfall, the following distributions are used, based on the generation of random numbers:

$$k = \begin{cases} e^{(4 \text{rand})-2} & \text{if } P_{\text{event}} \leq 30 \text{ mm} \\ 0.145 \text{randg}(5.43) & \text{if } P_{\text{event}} > 30 \text{ mm} \end{cases} \quad (3)$$

where  $k$  is the multiplicative factor applied to every SPP rain value, calculated for every rain event. Two rain events are considered as independent when they are separated by more than 12 h, i.e., when they are separated by more than 12 h without rainfall. For rain events of less than 30 mm, the altered rain will have the form expressed in the upper part of Eq. (3), following an exponential function determined by the generation of uniformly distributed random numbers (*rand*). For large rain events of more than 30 mm,  $k$  will change, using in this case a gamma distribution to generate the random numbers (*randg*), defined by two shape parameters (0.145 and 5.43) (Marsaglia and Tsang, 2000). This change was made after observing how large rain events were problematic when using the exponential function at several sites. With the gamma-distributed function, we avoid large potential errors for intense rain events, improving overall results for the ten sites. In the example shown in Fig. 2b, the first rain event is larger than 30 mm and the lower part of Eq. (3) is applied, while the upper one is used for the second event of 24th May as it is lower than 30 mm.

3. We compute the root mean squared error (RMSE) of every simulated soil moisture time series (for a total of 100 RMSE) compared to the SMOS measurements in each period (black stars in Fig. 2b).
4. Based on the previously calculated 100 RMSE values associated to the 100 simulations, only a subset (*kept*) of them are selected (red lines in Fig. 2c), corresponding to the 30 simulations with the lowest RMSE. This *kept* number is variable depending on the quality of SMOS (Eq. (4)), since the more reliable SMOS is in a specific period, a lower number of *kept* will be needed (i.e., a *kept* of 10), meaning



**Fig. 4.** Results of LMAA applied to CMORPH real-time product (bars for API and circles for SURFEX). a) 24h RMSE change (mm/day). b) 24h Pearson correlation change. c) Absolute cumulative error change (mm/year). The results are shown for 10 sites (separated by vertical dashed lines) and for years from 2010 to 2015 (except USA 4, which is only from 2010 to 2013). Green colours indicate improvements and red ones worsening regarding the performance scores of the original products (see Fig. 8 for information about the initial quality of the used SPP and Fig. 9 for the final performance scores obtained after the LMAA application). (For interpretation of the references to colour in this figure legend, the reader is referred to the web version of this article.)

that we will trust more the correction provided by the assimilation. On the other hand, the lower the quality of SMOS is, the higher this number will be (i.e., a *kept* of up to 60), meaning that the correction will be less accurate and therefore we will give more importance to the original soil moisture value (blue line in Fig. 2).

The quality of SMOS is determined for every period ( $Q_{period}$ ) based on the mean of the quality of every SMOS measurement ( $Q_{SMOS}$ ) in the period, which will depend on the value of  $dqx$ ,  $Chi2$  and  $RFI$  normalized by their minimum and maximum values (Eq. (4)):

$$Q_{SMOS} = \frac{(dqx/0.045)+(RFI/0.45)+(Chi2-1/3.5-1)}{3}. \quad (4)$$

Since  $Q_{SMOS}$  and  $Q_{period}$  range between 0 and 1 (1 for the worst quality and 0 for the best one), we fixed a *kept* value of 10 if  $Q_{period}$  is lower than 0.1, 20 if it is between 0.1 and 0.2, 30 when it is between 0.2 and 0.3, 40 for values between 0.3 and 0.5, 50 for values between 0.5 and 0.7 and 60 when  $Q_{period}$  is larger than 0.7. This is one of the many different possible ways of taking into account the SMOS quality for the correction provided by the assimilation technique.

5. From the red lines in Fig. 2c, their associated rainfall time series (red bars in Fig. 2c) are averaged (green bar in Fig. 2d) to provide a corrected rainfall estimate. The green line in Fig. 2d represents the corrected soil moisture associated with the corrected rainfall, which

final value will be used to initialize the next simulated period.

Here, LMAA is applied on a yearly basis to every site, dividing each year into sub-periods containing 6 unique SMOS retrievals in a 9 days maximum period following the beginning of a rain event. However, the assimilation is not applied when no SMOS data are available or during periods without rain. In these cases, the simulation continues in order to provide the initial value of soil moisture for the next assimilated period, which will start just before the starting of a new rain event. This configuration could be easily applied operationally and will provide a new corrected rainfall within a maximum of 9 days after the start of every rain event (less if there are 6 SMOS data before).

### 3. Results: LMAA evaluation

Fig. 3 shows an example of the correction performed by LMAA for USA 1 site in 2012. The blue line in this figure shows the annual cumulative rainfall originally provided by CMORPH, while the black line shows the real rainfall observed at this site based on *in situ* rain gauges. The green line shows the final results obtained after the application of LMAA (in this example with SURFEX), showing how the methodology provides a successful correction of the initial product (for the annual cumulative rainfall, for the 24h-RMSE and for the 24h-Pearson

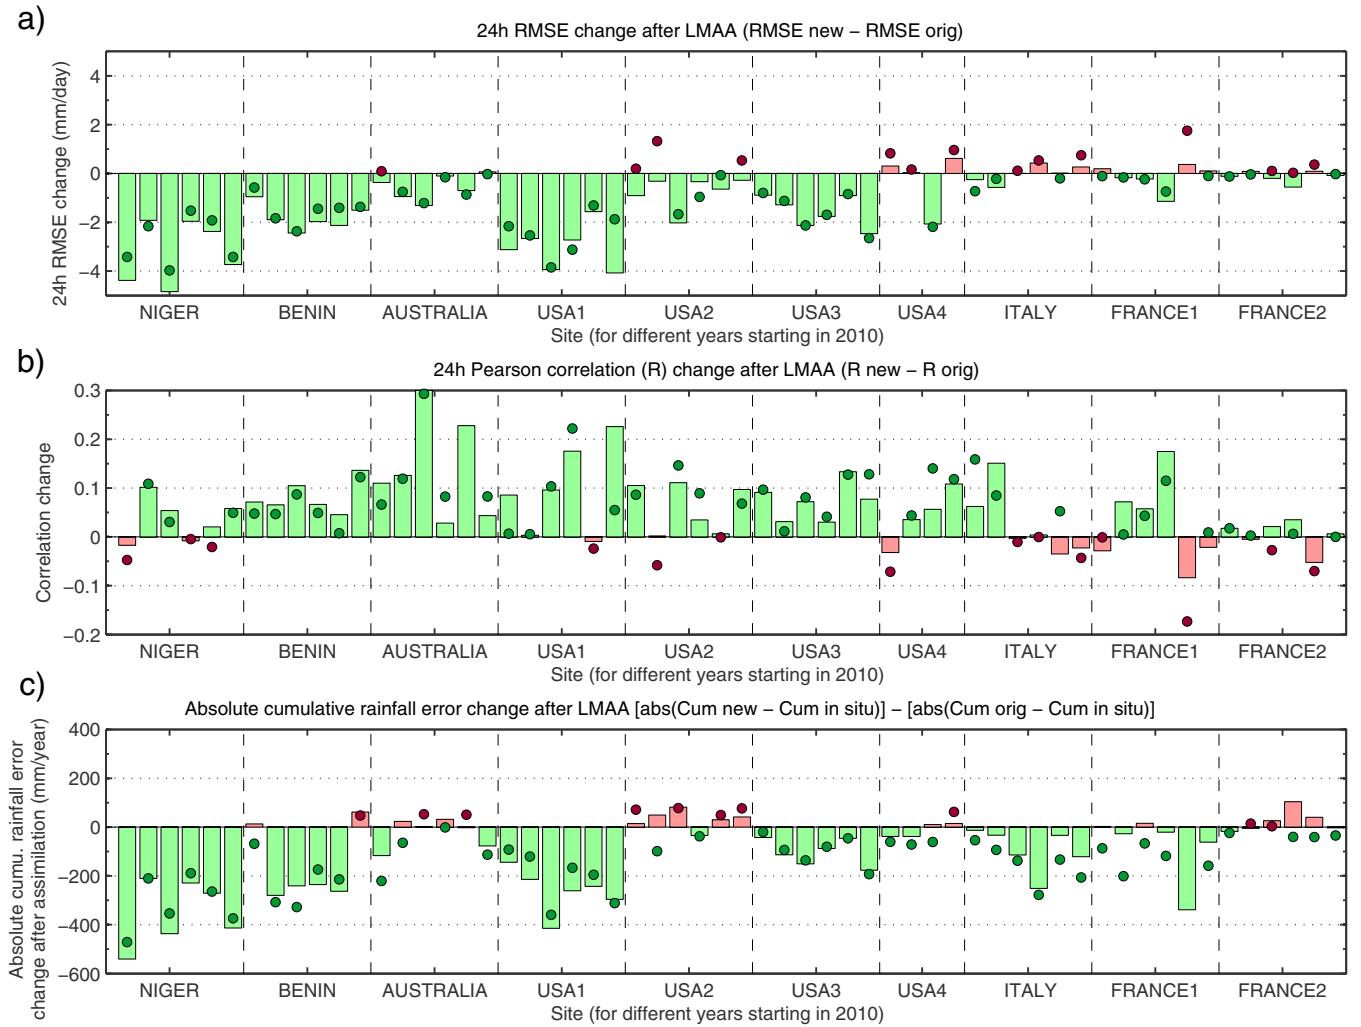


Fig. 5. As in Fig. 4, but for PERSIANN real-time product.

correlation).

The results for the rest of the sites and years are shown in Figs. 4, 5 and 6 with the performance scores changes obtained after the application of LMAA for each particular site and year to the CMORPH, PERSIANN and TRMM-3B42RT real-time datasets respectively. The evaluation of the methodology is performed in terms of changes between original and new 24h-RMSE, 24h-Pearson correlation ( $R$ ) and absolute error in the annual cumulative rainfall. All these performance indicators have been calculated using *in situ* rainfall information as the reference benchmark, which is not used at all in the LMAA application.

It should be noted that all zero values are included in the rainfall time series used for the computation of  $R$  and RMSE. In the case of the RMSE, we also computed the unbiased RMSE changes (not shown) and we obtained very similar results than with RMSE. This result suggests that the RMSE is mainly driven by the random error and, therefore, the bias (or systematic error) is less important. If we remove the values with zero in both time series for the RMSE computation, the RMSE values are logically larger, since we do not include the zero-zero correspondences which decrease the mean error. In this case, the differences between the changes obtained by using RMSE or unbiased RMSE are slightly more appreciable but still low, indicating again that the main contribution to the errors is due to the random errors. This motivated us to use the RMSE (not unbiased) including the zero values in the rainfall time series.

In Figs. 4, 5 and 6, the upper panels (a) show the 24h RMSE change (original minus corrected) after the LMAA application, i.e., it will be

negative when the corrected rainfall has a lower 24h-RMSE than the original one (marked in green, improvement). The middle panels (b) show the same but for the 24h-Pearson correlation change, being now positive when there is an increase of the correlation with the *in situ* data after the application of the LMAA. Finally, the bottom panels (c) show the change in the absolute error of the cumulative total annual rainfall when compared to the *in situ* data. That is, one bar will be negative and green (improvement) if the cumulative rainfall bias (absolute value) is larger for the original real-time SPP than for the corrected one. The use of absolute error values is just a matter of making comparable biases of different signs. In order to illustrate the differences obtained between models, the results shown with bars are those obtained with the API model while the ones obtained with SURFEX are shown with circles.

In general, green colours dominate over red ones in these figures, meaning that the methodology is able to correct and improve the original RMSE, correlation and annual cumulative rainfall provided by the three SPPs. The correction is substantial in sites like Niger, Benin, USA 1 and USA 3 and satisfactory, but limited, at USA 2 and the Australia sites. However, the results are worse in other sites, such as USA 4, Italy, France 1 and France 2. As it will be discussed in the next section, these results are linked to the limitations of the methodology in sites affected by RFI, mountains or extensive forest cover. In fact, as commented in Section 2, some of these sites were intentionally chosen because these conditions represent a stern test for the inversion of SMOS surface soil moisture retrievals.

The potential of the methodology is strengthened due to the fact

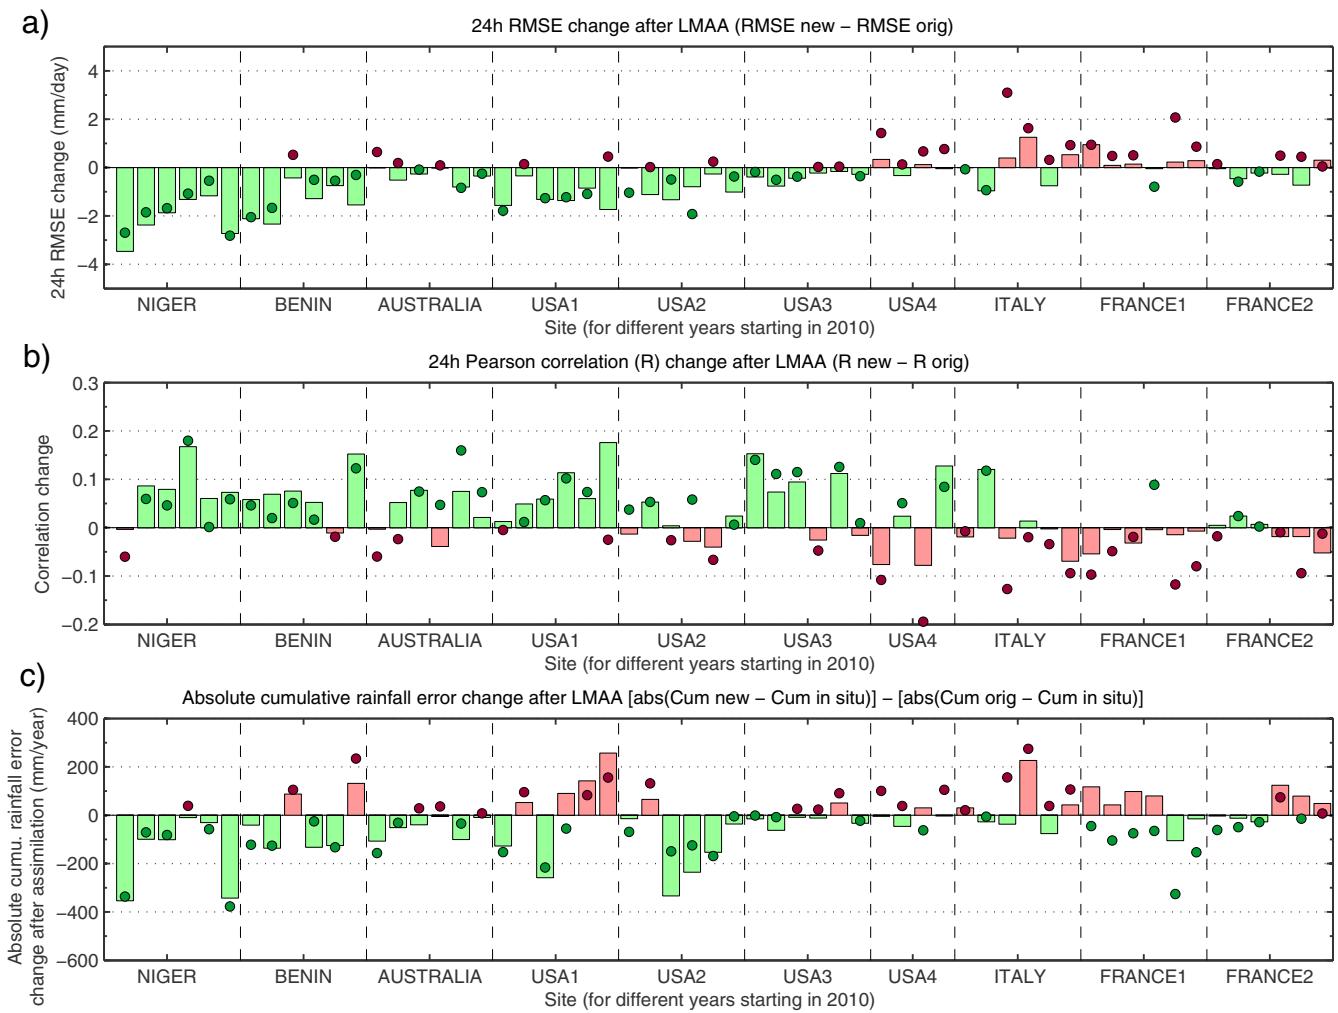


Fig. 6. As in Fig. 4, but for TRMM-3B42RT real-time product.

that the improvements are observed in many of the evaluated sites for the three different SPPs. It is worth noting that the correction is more powerful for some products than for others, which indicates that a dependency could also exist with the features of the original rainfall dataset aimed to be corrected. For example, the increase in the 24h-RMSE error (worsening) of around +2 mm/day observed in USA2 in 2014 for CMORPH (Fig. 4) is not observed for the other products (Figs. 5 and 6), since it is partly caused by a quite large and prominent error of the real time version of this product in a rain event. It should also be noted that the correction for the PERSIANN dataset (Fig. 5) is better than for the other datasets in general. This is related to the worse initial performance scores of PERSIANN compared to the other products in these 10 sites, which allows for a more substantial correction. On the other hand, the bias in the annual cumulative rainfall are also corrected for the three different SPPs (Figs. 4–6(c)), indicating that the correction in all three products converges to the desired real value (*in situ* rainfall). This means that the correction offered by the methodology always tends to the reference value despite the initial product.

The comparison between both models (bars for API and stars for SURFEX) reveals how, in general, the API model produces slightly better results than the more-complex SURFEX model. The exceptions to this tendency are, for example, in 2010 and 2013 at the USA2 site when correcting TRMM-3B42RT (Fig. 5a,b) or at USA 3 site, where the correction offered by the two models is slightly better for SURFEX. In other cases, SURFEX can lead to much larger errors than API, such as for example in Niger 2011 correcting CMORPH (Fig. 4), when SURFEX worsens the RMSE and R results. The comparison between models is

analysed in detail in Section 4.3.

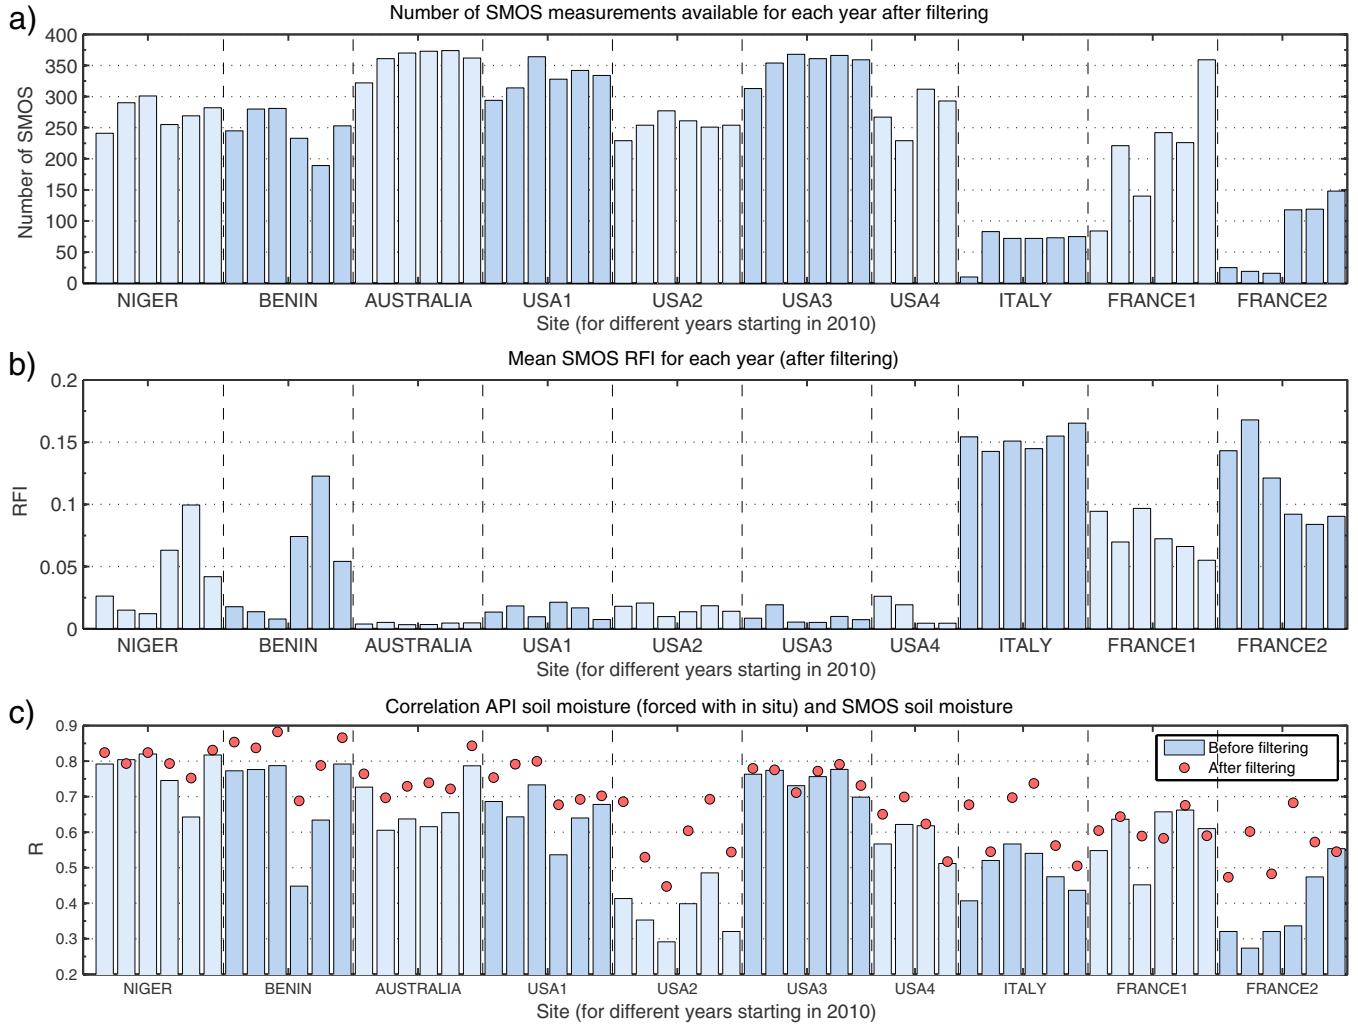
#### 4. Discussion: analysis of data, models and LMAA

The accuracy of the correction performed by LMAA is primarily affected by the initial quality of the two main datasets: soil moisture from SMOS and the SPP to be corrected. The quality of these two datasets is analysed in this section in order to determine their influences on the observed corrections (improvement or worsening). Possible error in the model simulating the soil moisture evolution is a third source of error and, in fact, out rationale for comparing two models of different soil moisture process complexity with different soil moisture representation. A fourth source of errors could be the assimilation technique, which is also studied via an experiment using *synthetically generated* SMOS data.

We are aware that there could be also some uncertainty in the *in situ* rainfall data used as reference. However, it is not possible to check the accuracy of these datasets and they constitute the most accurate available dataset to be considered as the reality. Some uncertainty could also exist in the additional atmospheric data used to force the models (from MERRA-2), nonetheless, the effect of these variables in the soil moisture evolution can be assumed as less important compared to the impact of rainfall.

##### 4.1. SMOS information

Figs. 4–6 demonstrate that sites exist where the correction of LMAA



**Fig. 7.** Information about SMOS data. a) Number of SMOS data per year used for the assimilation, i.e., after the filtering procedure. b) Mean radio frequency interference (RFI) for every site and year (after filtering). c) Correlation between soil moisture from SMOS and obtained with the API model (similar results are obtained for SURFEX).

is not successful for any of the SPPs (USA 4, Italy, France 1 and France 2). This suggests that the main problem at these sites is errors in the SMOS soil moisture retrieval used in the assimilation. Fig. 7a shows how the number of SMOS used for each site differs, especially due to the application of the filtering previously performed to remove suspicious data (see Section 2). The European sites (especially Italy and France 2) are the sites most affected by this filtering and therefore, insufficient SMOS data are available to effectively correct rainfall. At these sites, even the data used (after the filtering process) still presents the highest RFI values used in the evaluation (Fig. 7b) - thus reducing the accuracy of the assimilation. On the other hand, Fig. 7c shows the correlation of SMOS data (before and after filtering) with the soil moisture simulated by the API model when forced with the *in situ* rainfall. The correlation normally increases for the filtered data (red circles) and is precisely lower in sites highly affected by RFI filtering (Italy, France 1 and France 2), not especially high in USA 4 (mountains) or in USA 2 (high percentage of forest) - further indicating the relatively lower accuracy of SMOS at these sites. The correlation values for Niger, Benin, USA 1, USA 3 and Australia are quite good in comparison with the other sites, in accordance with the LMAA results.

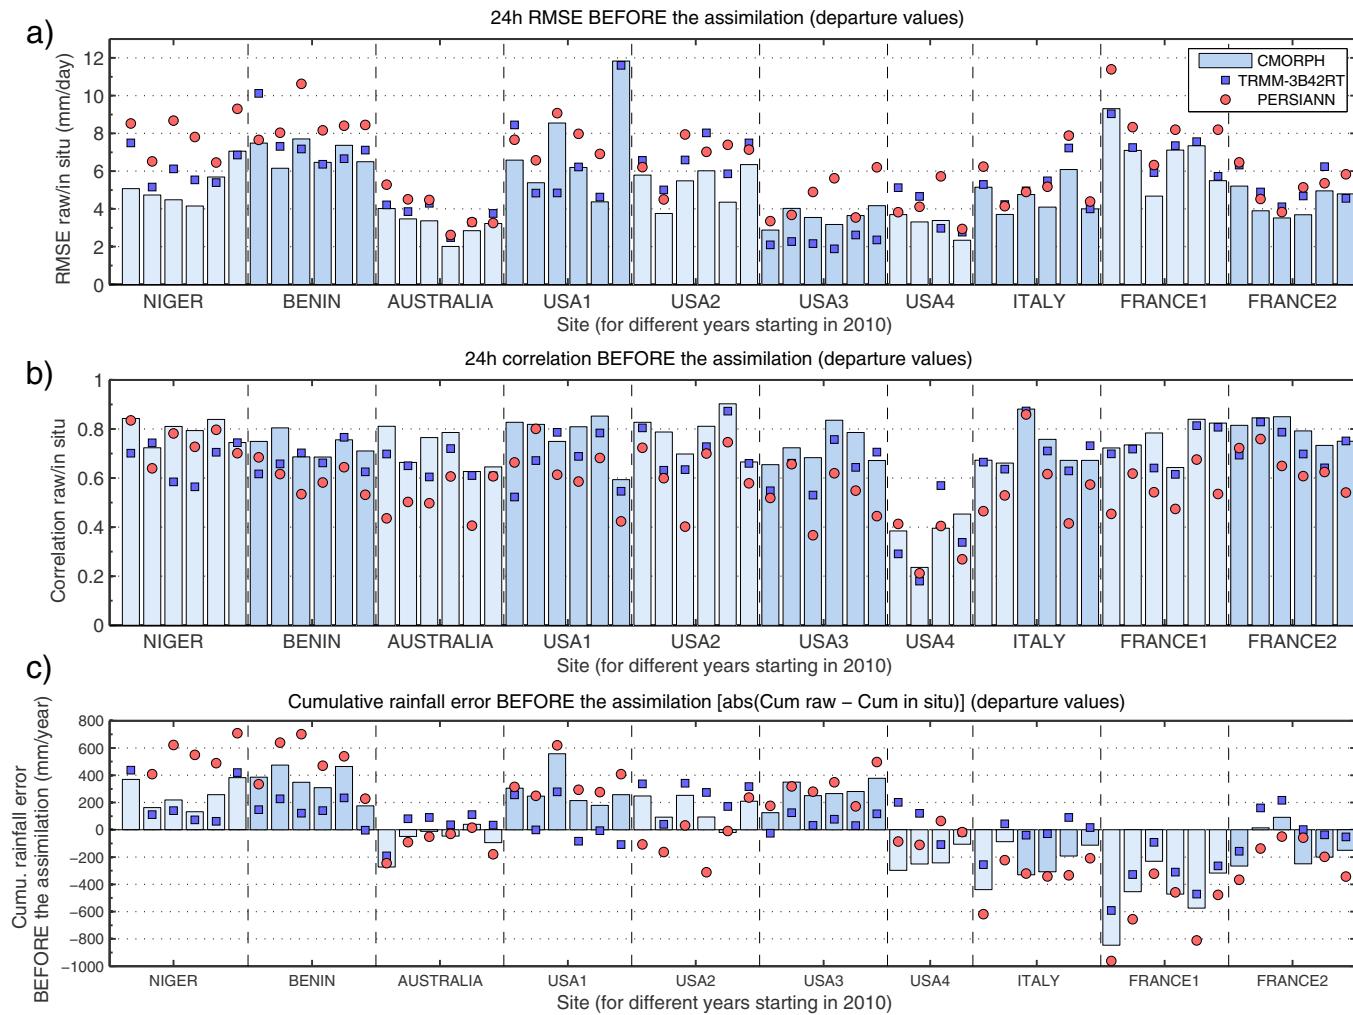
On the other hand, the SMOS quality in Niger and Benin sites is also lower during 2013, 2014 and 2015 due to a temporal source of RFI in the area. However, enough SMOS data remain after the filtering procedure that results are minimally affected. In fact, the variable number of *kept* ensemble members depending on the SMOS quality is precisely

designed to give more importance to the rainfall value from the original product when the quality of SMOS data is low (see Section 2). The same thing happens in USA 2, where the correlation shown in Fig. 7c is relatively low but there is still a sufficient number of SMOS data after the filtering process, since the SMOS quality indices are not related to the amount of vegetation. For this reason, the observed correction at this site is not always successful.

#### 4.2. Real-time SPP information

The quality and number of SMOS retrievals is not the only factor impacting the success of the LMAA method. The other main datasets used for the assimilation correction are the real-time SPPs we are trying to correct. Thus, if these datasets present remarkable differences with the *in situ* data, the expected correction can be limited, since the LMAA methodology cannot create new rain events nor totally remove them - even if the SMOS data suggest it. That is, LMAA can only modify the initial rainfall amount provided by SPP.

Fig. 8 shows RMSE, R and annual cumulative rainfall error metric values for the CMORPH (bars), TRMM-3B42RT (squares) and PERSIANN (circles) real-time products before the application of LMAA. These values show how there are some sites with problems for the retrieval of rainfall from satellite, like USA 4, where the initial correlation is noticeable low (normally less than 0.4). There is also a negative rainfall bias at this site for some products (approximately -200 mm for



**Fig. 8.** Information about the three SPPs tried to be corrected. a) Initial 24h-RMSE before the assimilation. b) Initial 24h-Pearson correlation before the assimilation. c) Initial annual cumulative rainfall error before the assimilation [abs(Cum raw – Cum in situ)] (departure values). CMORPH values are represented with bars, TRMM-3B42RT with blue squares and PERSIANN with red circles. (For interpretation of the references to colour in this figure legend, the reader is referred to the web version of this article.)

**Table 2**

Mean scores calculated from 10 sites and 6 years data for the three different SPPs. First values indicate the initial values (original real-time products) and second values the final ones obtained after the LMAA correction (final product) with the API model.

	24h RMSE (mm/day)	R	Abs. cum. error (mm/year)
CMORPH	5.1/4.4	0.73/0.75	254/183
TRMM-3B42RT	5.5/4.8	0.66/0.69	153/127
PERSIANN	6.5/5.3	0.58/0.64	332/227

CMORPH, shown with bars in Fig. 8c), which is a markedly large value compared to the mean cumulative annual rainfall of this site (472 mm as shown in Table 1). This suggest that the real-time SPP is missing an important amount of precipitation - likely due to the inability of the SPP to detect snow precipitation during the winter months (USA 4 site is located in the Rocky Mountains (Reynolds Creek)). In any case, it should be noted that the rainfall correction based on SMOS data is not applicable during snowy periods, since soil moisture retrieval from SMOS in snow-covered surfaces is not possible, representing a limitation of the presented LMAA methodology.

On the other hand, the relatively low values of the initial bias of the cumulative annual rainfall (more accurate) in Australia and USA 2 reduce the need for correction in these sites, except at USA 2 for TRMM-3B42RT, where there are initial biases of around +300 mm/year (Fig. 8c), values that are normally successfully corrected (see Fig. 6c).

**Table 2** shows the comparison between the initial (original values) and the corrected (new values) RMSE, R and annual cumulative error for the three different products, based on a mean performed for all the sites and years. The SPP with lower initial scores is PERSIANN and this product shows better corrections. The same conclusion can be extracted from a quick comparison between the values shown in Figs. 8 and 9, which represent the final performance indicators after the LMAA application with the API model. That is, Fig. 9 and Table 2 show how there exists a convergence towards the *in situ* values after correction of the three products (i.e., generally decreasing the RMSE, increasing the correlation and correcting the annual cumulative rainfall). The correction is successful for all the real-time products assimilated, although there also exists a dependency on the initial quality of the original SPP, as it has been shown in this subsection.

#### 4.3. Model analysis: API versus SURFEX

Figs. 45–6 show slightly better results for LMAA using API model than SURFEX. This is a very interesting result, since it suggests that the use of a more sophisticated (and more expensive computationally) model is not necessary to correct rainfall with the LMAA methodology and SMOS data. This result does not necessarily mean that SURFEX does a worse job simulating the soil moisture dynamics. Table 3 shows the correlation of *in situ* soil moisture from several soil moisture stations available at each site and the simulated values of this variable by API

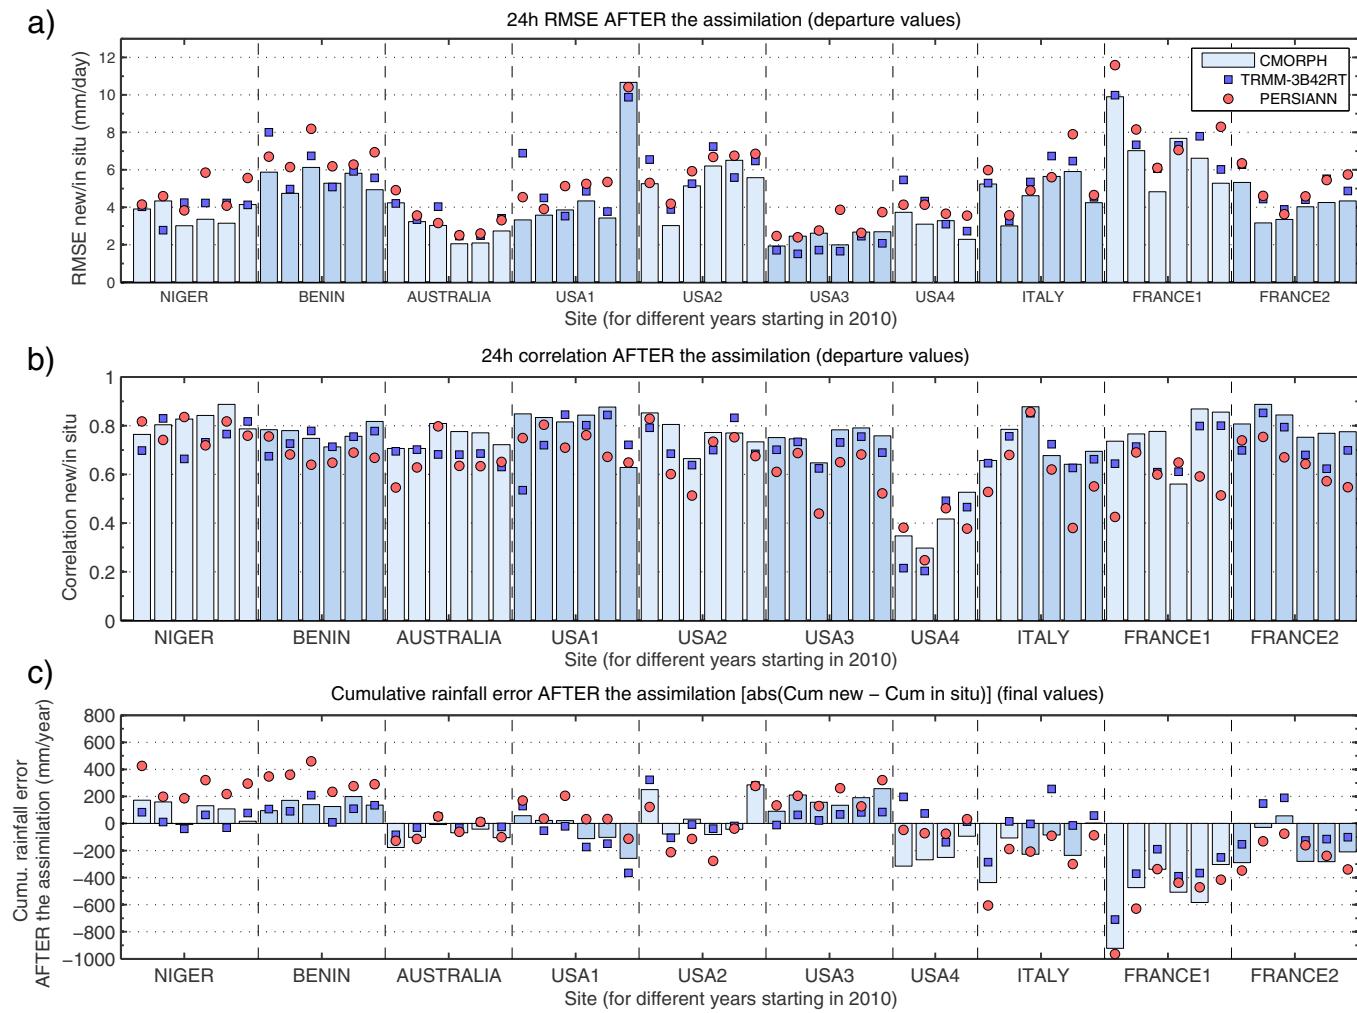


Fig. 9. As in Fig. 8 but for the products obtained after the correction performed by LMAA (final results offered in this study).

Table 3

Correlation between *in situ* soil moisture and soil moisture simulated by API and SURFEX when forced with *in situ* rainfall. The most appreciable differences are marked in bold.

Site	R	R
	API	SURFEX
Benin	<b>0.98</b>	0.89
Niger	<b>0.95</b>	0.91
Australia	<b>0.89</b>	0.81
USA1	0.89	0.89
USA2	0.92	0.92
USA3	0.80	<b>0.86</b>
USA4	<b>0.84</b>	0.81
Italy	0.75	<b>0.88</b>
France 1	0.89	0.89
France 2	0.78	0.78

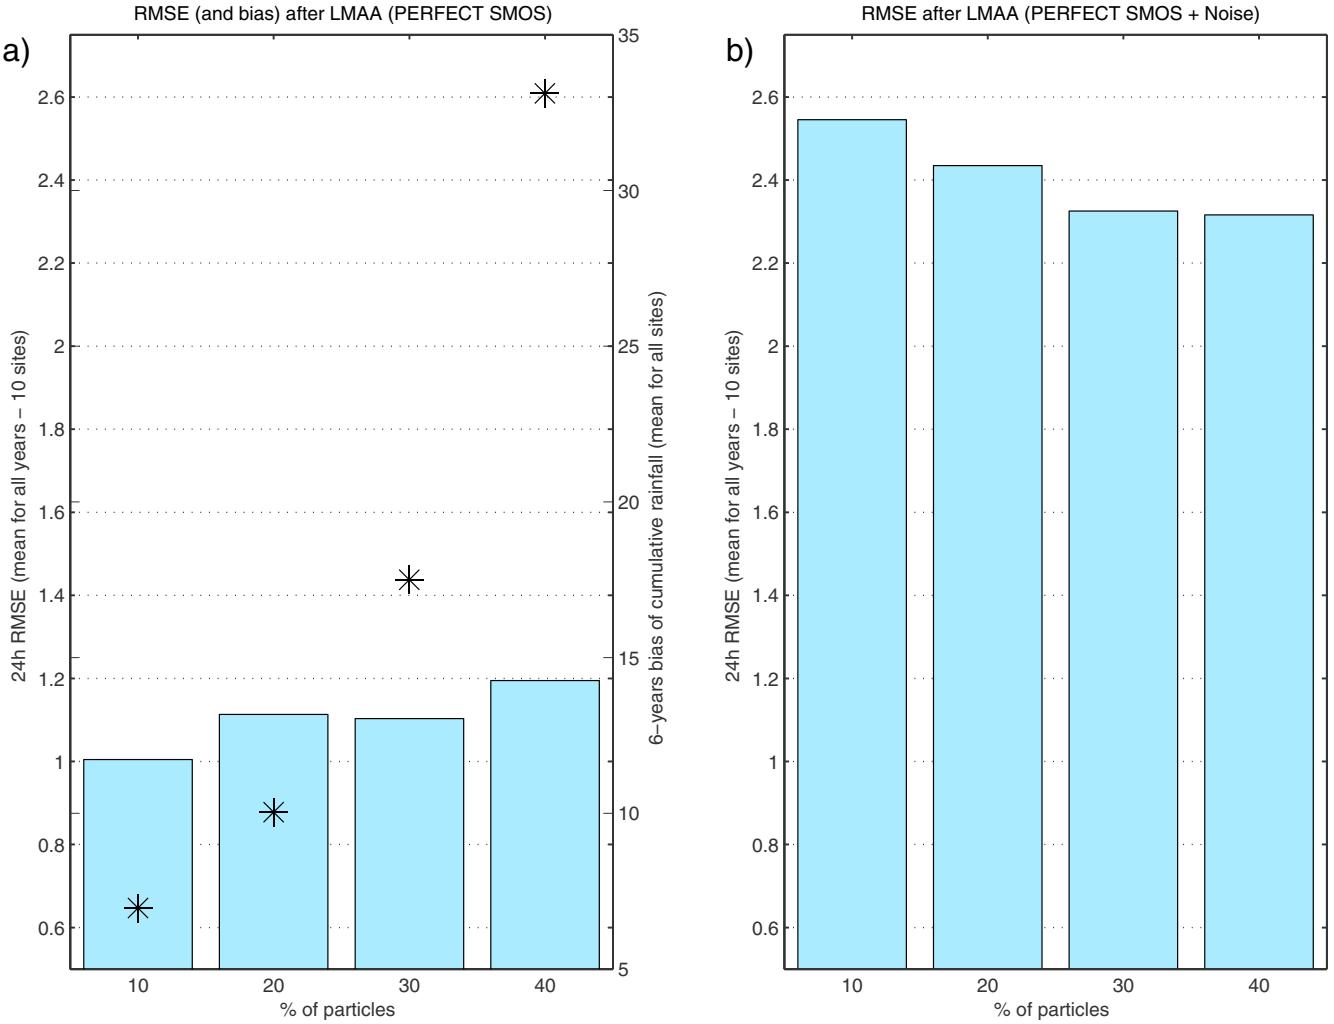
and SURFEX forced with *in situ* rainfall. The intention of this table is not to analyse the absolute values, which can be influenced by uncertainties in the *in situ* rainfall and by the real representativeness of the soil moisture probes, factors out of the scope of this study. The only intention of Table 3 is to compare the correlation between both models, in order to have an idea about which model is more realistically representing the soil moisture evolution.

The high values shown in Table 3 strengthen the conclusion that both models are able to correctly represent the soil moisture. However, in some cases, important differences are observed between the models

when the LMAA methodology is applied (Figs. 45–6). The values in Table 3 are slightly better for API in sites where the LMAA correction is also slightly favourable for this model (Niger, Benin and Australia). The results of the correction are similar when both land-surface models have the same skill simulating the soil moisture (USA 1 and USA 2). Some advantage is observed for SURFEX in USA 3, leading to very slight improvements compared to the results of API, especially for the correlation values. This comparison is not useful in sites with limited SMOS data quality (USA 4, Italy, France 1 and France 2), since the observed corrections are not successful.

#### 4.4. Analysis of assimilation algorithm: synthetic experiments

Finally, it is worthwhile to analyse the accuracy and the limitations of the LMAA technique itself by means of synthetic experiments. One limitation is that LMAA uses artificial rain perturbations within a limited range of values, which can either be too small or too large in some cases. A second limitation is related to the definition of the particle filter, which uses the mean of an ensemble of simulations to correct the initial values and not discrete and absolute values like for example the Kalman Filter. For the sake of clarity, the analysis shown in this section is performed using only the API model. The procedure is as follows: *perfect* (synthetic) soil moisture data are extracted from soil moisture time series simulated by the API model when forced with *in situ* rainfall (considered as the synthetic truth). The frequency of these data is set to the same number of the real SMOS (and at the same time) before filtering, i.e., between 300 to 400 data per year. In doing so, we remove



**Fig. 10.** 24-h RMSE change after the assimilation (bars). Note how the original product starts with a RMSE value of  $0 \text{ mm h}^{-1}$ . a) *Perfect SMOS*, including the bias in 6-year cumulative rainfall ( $\text{mm/6 years}$ , mean for all sites), indicated with stars. b) *Perfect SMOS + noise*, i.e., with a controlled noise of  $0.04 \text{ m}^3 \text{ m}^{-3}$ .

the uncertainties of the SMOS accuracy, creating the *perfect SMOS*. These data are used in LMAA in two synthetic experiments.

#### 4.4.1. Synthetic experiment I: perfect SMOS correcting perfect rain

In this experiment, *perfect SMOS* data are used in LMAA to correct the *in situ* rainfall itself, removing also the uncertainties of the SPP (since in this case the original rainfall is the same than the one used as reference for the evaluation). Thus, if the methodology is perfect, the correction applied after LMAA should be null and the new corrected value should be equal to the original one. However, the methodology itself can artificially change the rainfall, slightly decreasing the correlation and slightly increasing the RMSE and the annual cumulative error of the rainfall time series obtained after the assimilation when compared to the *in situ* original ones. These changes are caused by the fact that LMAA uses the mean of limited number of *kept* particles (a fixed number in this synthetic experiment). These artificial variations of the rainfall amount are especially important in sites with a larger number of intense rain events (e.g. USA 1 or USA 2, not shown), since larger rain event can lead to larger modification of the rain estimates. This is especially important when the soil moisture after the original rain event is close to the saturation, i.e., the soil moisture will not increase more above a rainfall threshold, since all the extra rain will be converted in runoff. In these circumstances, some of the new artificially generated rain amounts produce approximately the same soil moisture, being impossible to increase more this variable. These soil moisture

time-series will have the same error when compared to the assimilated data (*perfect SMOS*) and, finally the lines used for the mean computation (*kept*) will form an asymmetric distribution (slightly shifted to larger values), resulting in an artificial increase of the rainfall. The same effect is also observed under conditions close to the minimum soil moisture possible, but with less effect, since the change in rainfall will be lower than in the saturation case. These limitations of the methodology can be especially problematic in the real experiment when SMOS soil moisture retrievals are above the soil moisture obtained with the original rainfall. In these real cases, LMAA can predict unrealistic overestimation in the corrected rainfall, although in other cases this increase in the rain amount was needed to apply successful corrections. One possible solution is to exclude large rain events (e.g. above 100 mm/event) from the correction, but after several sensitivity experiments, it was seen how the best solution was to limit the possibility of increase, as explained in Section 2 and in Eq. (3), providing the best results for all the evaluated sites. Other optimal solutions could improve the results when LMAA is applied over specific regions with particular precipitation regimes.

Coming back to the errors associated to the LMAA correction in synthetic experiment I, Fig. 10a shows the mean RMSE obtained in the evaluation of the rainfall obtained using different number of *kept*. This figure indicates how the lower the numbers of *kept* is, the lower the error is, tending to RMSE of  $0 \text{ mm/day}$  with only 1 line, since that line would be the original one, i.e., the soil moisture produced by the *in situ*

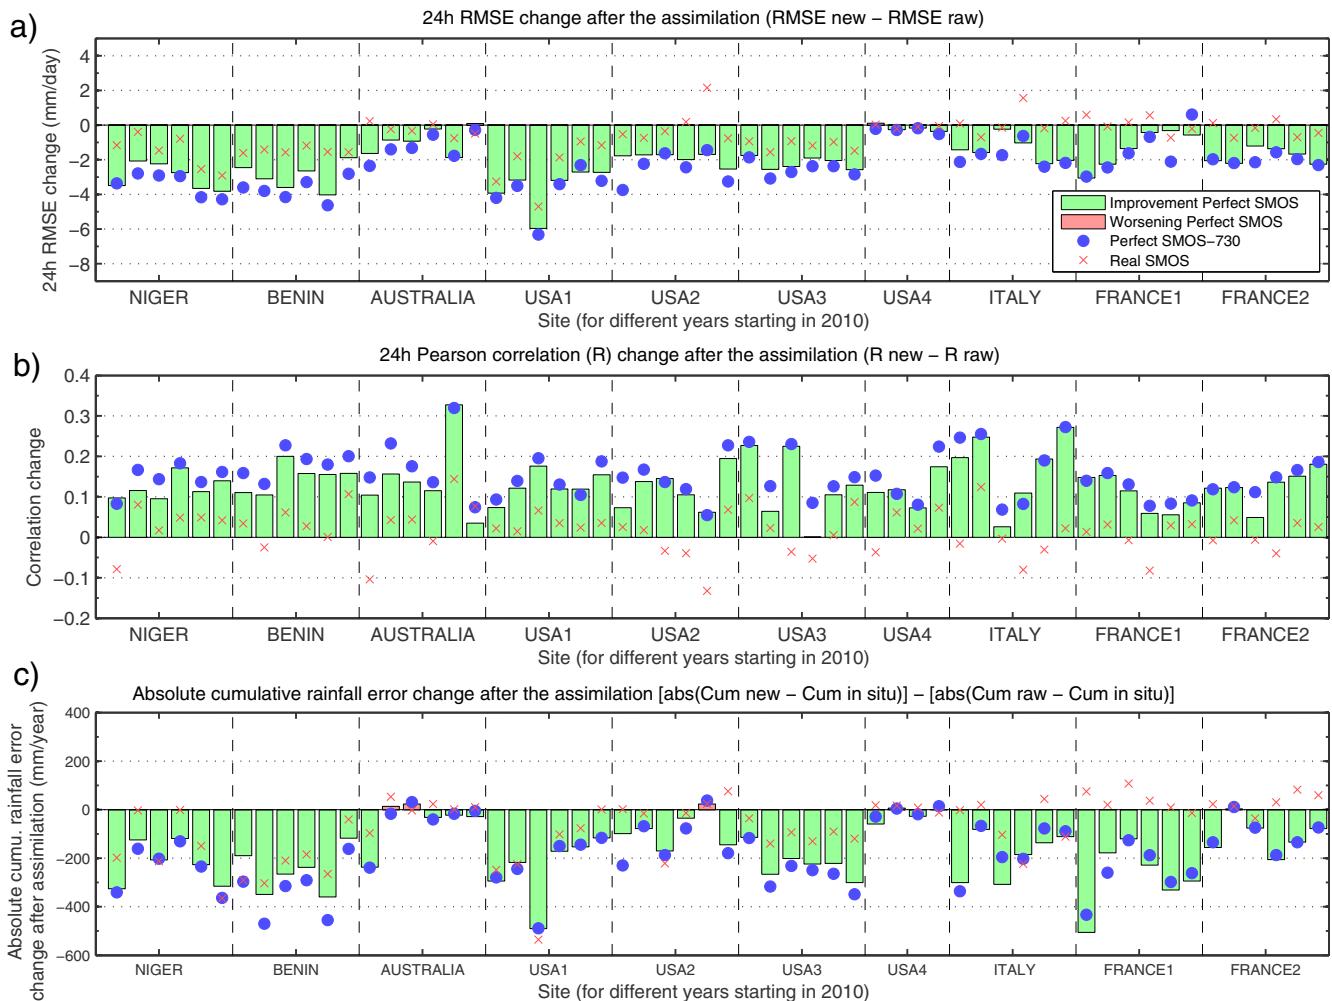


Fig. 11. As in Fig. 4 but for the synthetic experiment II, using *perfect SMOS* (bars) and increasing the data frequency (*perfect SMOS-730*), shown with blue circles. The results obtained in Fig. 4 (for API model) with real SMOS are shown here with red x symbols for comparison. (For interpretation of the references to colour in this figure legend, the reader is referred to the web version of this article.)

rainfall in this synthetic experiment. The same tendency is observed in this figure for the total bias of the cumulative rainfall (indicated with stars in Fig. 10a) in the six years evaluated (mean for all sites), with positive bias values, indicating the tendency to overestimate the rainfall due to the commented effect. These results are in accordance to the argument of the previous paragraph, since less *kept* lines means that they will be closer to the original one (and less of them will be affected by the saturation problem), resulting in a mean close to the original one. This represents a limitation of the PF method in comparison with a Kalman Filter one, which could be more appropriate when assimilating extremely accurate data, but which is not the case for SMOS soil moisture retrievals.

On the other hand, Fig. 10b shows the same than in Fig. 10a, but using a variation of *perfect SMOS*. In this case, a controlled noise has been introduced in *perfect SMOS*, named now *perfect SMOS + noise*, which is somehow closer to the real SMOS data but with a controlled error of  $0.04 \text{ m}^3 \text{ m}^{-3}$ . In this case, the RMSE is higher (as expected) compared to the one shown in Fig. 10a, but it is also observed that the RMSE tends to decrease when the number of *kept* increases. That is, if SMOS were perfect (Fig. 10a), it would be appropriate to select a low number of *kept*. However, Fig. 10b suggests that it would be better to select a higher number of *kept* when a systematic error is introduced in the assimilated soil moisture data. The quality and accuracy of the real SMOS data is highly variable depending on the site, surface conditions, RFI, etc. This motivates our application of a variable number of *kept*

depending on the quality of SMOS (see Section 2), evaluated with dqx, RFI and Chi2 parameters. Note how the bias is not included in Fig. 10b because the noise makes its analysis more difficult due to the compensating effect (positive and negative) of this score.

#### 4.4.2. Synthetic experiment II: *perfect SMOS* correcting SPP

The previous synthetic experiment has shown how LMAA can slightly degrade the results, but this degradation is partially controlled through the use of a variable number of *kept* and changing the perturbation distribution for large rain events. On the other hand, this degradation does not necessarily exist in the real world (using real SMOS), since the real application of LMAA is based on an ensemble distribution of the assimilated variable. In this second synthetic experiment, *perfect SMOS* is applied directly to the SPP, with the objective of analysing the maximum correction possible with the methodology (i.e., if SMOS were perfect and using a fixed *kept* value of 10).

Results of a hypothetical rainfall correction using *perfect SMOS* are shown in Fig. 11 with bars for CMORPH, achieving very good results for almost all the sites/years in comparison with the results obtained in Fig. 4 using real SMOS (also indicated in Fig. 11 with red x symbols for comparison). In general, the results obtained with synthetic experiment II are much better in sites highly affected by RFI (Italy, France 1 and France 2), since the undesired effect of RFI and SMOS filtering is removed in these cases. In the other sites, the results are obviously better with *perfect SMOS* but it can be seen how real SMOS offers good results

when compared to the maximum correction possible (*if SMOS were perfect*).

Lastly, in order to investigate the possible effect of SMOS frequency in the correction, we tested the results obtained by increasing artificially the frequency of perfect SMOS time series, now with two SMOS per day (named *perfect SMOS-730*, since there will be 730 data for each year (732 for 2012)), shown in Fig. 11 with blue circles. It is shown how the results could be even better, representing a potential improvement by utilising, for example, a combination of measurements from SMOS and SMAP (Soil Moisture Active Passive from NASA).

## 5. Conclusions

This study evaluates the ability of the LMAA methodology to correct satellite-derived real-time rainfall estimates through the assimilation of SMOS soil moisture into two models of different complexity (API and SURFEX). LMAA has been optimized based on numerous sensitivity experiments to provide the best results in terms of rainfall correction. These sensitivity experiments are not shown in this study, but the final technical configuration and the description of LMAA is extensively explained in Section 2 to facilitate its potential application to other datasets. The evaluation of LMAA is performed using quality-controlled *in situ* rainfall data from ten locations worldwide with different land cover and climate features. Results demonstrate how the approach is able to improve the rainfall accumulation estimates acquired from three different real-time SPP (CMORPH, PERSIANN and TRMM-3B42RT). It is also shown how the methodology is limited in sites affected by anthropogenic RFI emission and/or complex topography. In these areas, the two main datasets used in the methodology (SMOS and SPP) present difficulties. Although highly vegetated sites were *a priori* also difficult sites for the lower-accuracy of the SMOS retrieval, the results suggest that this feature does not significantly affect the correction of rainfall. Finally, large rain events leading to saturation conditions could also be problematic in some specific cases. Although the methodology has been adapted to take into account this problem, extreme rain events should be treated with care in real applications. On the other hand, this is the first time that a simple land-surface model (API) is compared to a state-of-the-art and more sophisticated one (SURFEX) for the correction of rainfall through satellite soil moisture assimilation. The results show how API provides slightly better results than SURFEX in general, which is a very important finding due to the much larger computational costs of SURFEX. The promising findings of this study open an ambitious line of future work through the application of the methodology in near real-time at the global scale.

## Acknowledgments

This work has been funded by ESA (ESA/AO/1-7875/14/I-NC). We would like to acknowledge several people for helping or providing data used for the evaluation: T. Vischel, G. Quantin, B. Boudevillain and S. Froidurot for data in France, Niger and Benin (AMMA-CATCH (<http://www.amma-catch.org>)). For the US sites, we would like to thank M. Cosh, McCabe and T. Jackson. Thanks to C. Rudiger and J. Walker for the data of Australia site (<http://www.oznet.org.au/mdbdata/mdbdata.html>). The authors would like to thank the SMOS CATDS-L3SM product ([http://www.cesbio.ups-tlse.fr/SMOS\\_blog/](http://www.cesbio.ups-tlse.fr/SMOS_blog/)) and the Terre Ocean Surfaces Continentales Atmosphère (TOSCA) program from CNES, the Global Modeling and Assimilation Office (GMAO) and the GES DISC for the dissemination of MERRA-2 data (<https://gmao.gsfc.nasa.gov/reanalysis/MERRA-2/>). Thanks to the National Center for Atmospheric Research Staff for CMORPH data (<https://climatedataguide.ucar.edu/climate-data/cmorph-cpc-morphing-technique-high-resolution-precipitation-60s-60n>). The TRMM-3B42RT data were provided by the NASA/Goddard Space Flight Center and PPS, which develop and compute the TRMM-3B42RT as a contribution to project TRMM-3B42RT, and archived at the NASA GES DISC (<https://GESDISC>).

[pmm.nasa.gov/data-access/downloads/trmm](http://pmm.nasa.gov/data-access/downloads/trmm)). The authors would like to thank the two anonymous reviewers for their helpful comments and suggestions, which have improved the quality and clarity of this research article.

## References

- Adler, R.F., Huffman, G.J., Chang, A., Ferraro, R., Xie, P.P., Janowiak, J., Rudolf, B., Schneider, U., Curtis, S., Bolvin, D., et al., The version-2 global precipitation climatology project (GPCP) monthly precipitation analysis (1979–present). *J. Hydrometeorol.* 4 (6), 1147–1167.
- Akponikpe, P.B., Minet, J., Gerard, B., Defourny, P., Bielders, C.L., Spatial fields' dispersion as a farmer strategy to reduce agro-climatic risk at the household level in pearl millet-based systems in the Sahel: a modeling perspective. *Agric. For. Meteorol.* 151 (2), 215–227.
- Ali, A., Lebel, T., The Sahelian standardized rainfall index revisited. *Int. J. Climatol.* 29 (12), 1705–1714.
- Allen, P.B., Naney, J.W., Hydrology of the Little Washita River Watershed Oklahoma: Data and Analyses. ARS-US Department of Agriculture, Agricultural Research Service (USA).
- Bosilovich, M., Lucchesi, R., Suarez, M., MERRA-2: File Specification. Tech. Rep., NASA GMAO Office Note 9 (Version 1.1), 75 Pp.
- Brocca, L., Ciabatta, L., Massari, C., Moramarco, T., Hahn, S., Hasenauer, S., Kidd, R., Dorigo, W., Wagner, W., Levizzani, V., Soil as a natural rain gauge: estimating global rainfall from satellite soil moisture data. *J. Geophys. Res. Atmos.* 119 (9), 5128–5141.
- Brocca, L., Hasenauer, S., Lacava, T., Melone, F., Moramarco, T., Wagner, W., Dorigo, W., Matgen, P., Martínez-Fernández, J., Llorens, P., et al., Soil moisture estimation through ASCAT and AMSR-e sensors: an intercomparison and validation study across Europe. *Remote Sens. Environ.* 115 (12), 3390–3408.
- Brocca, L., Moramarco, T., Melone, F., Wagner, W., A new method for rainfall estimation through soil moisture observations. *Geophys. Res. Lett.* 40 (5), 853–858.
- Brocca, L., Pellarin, T., Crow, W.T., Ciabatta, L., Massari, C., Ryu, D., Su, C.-H., Rüdiger, C., Kerr, Y., Rainfall estimation by inverting SMOS soil moisture estimates: a comparison of different methods over Australia. *J. Geophys. Res. Atmos.* 121 (20), 12,062–12,079.
- Cai, Y., Jin, C., Wang, A., Guan, D., Wu, J., Yuan, F., Xu, L., Spatio-temporal analysis of the accuracy of tropical multisatellite precipitation analysis 3B42 precipitation data in mid-high latitudes of China. *Plos*, one 10 (4) E0120026.
- Casse, C., Gosset, M., Peugeot, C., Pedinotti, V., Boone, A., Tanimoun, B., Decharme, B., Potential of satellite rainfall products to predict Niger river flood events in Niamey. *Atmos. Res.* 163, 162–176.
- Champeaux, J., Masson, V., Chauvin, F., ECOCLIMAP: a global database of land surface parameters at 1 km resolution. *Meteorol. Appl.* 12 (1), 29–32.
- Creutin, J., Obled, C., Objective analyses and mapping techniques for rainfall fields: an objective comparison. *Water Resour. Res.* 18 (2), 413–431.
- Crow, W., Bolten, J., Estimating precipitation errors using spaceborne surface soil moisture retrievals. *Geophys. Res. Lett.* 34 (8).
- Crow, W., van Den Berg, M., Huffman, G., Pellarin, T., Correcting rainfall using satellite-based surface soil moisture retrievals: the soil moisture analysis rainfall tool (SMART). *Water Resour. Res.* 47 (8).
- Crow, W.T., Huffman, G.J., Bindlish, R., Jackson, T.J., Improving satellite-based rainfall accumulation estimates using spaceborne surface soil moisture retrievals. *J. Hydrometeorol.* 10 (1), 199–212.
- DeChant, C.M., Moradkhani, H., Improving the characterization of initial condition for ensemble streamflow prediction using data assimilation. *Hydrol. Earth Syst. Sci.* 15 (11), 3399–3410.
- Delrieu, G., Andrieu, H., Anquetin, S., Creutin, J.D., Ducrocq, V., Gaume, E., Nicol, J., Cevennes-Vivarais Mediterranean hydro-meteorological observatory: the catastrophic rain event of 8–9 September 2002 in the Gard Region, France. In: Sixth International Symposium on Hydrological Applications of Weather Radar. Melbourne, Australia, pp. 2–4.
- Ebert, E.E., Janowiak, J.E., Kidd, C., Comparison of near-real-time precipitation estimates from satellite observations and numerical models. *Bull. Am. Meteorol. Soc.* 88 (1), 47.
- Fisher, R.A., The influence of rainfall on the yield of wheat at Rothamsted. *Philosophical Transactions of the Royal Society of London. Series B. Containing Pap. Biol. Char.* 213, 89–142.
- French, R., Schultz, J., Water use efficiency of wheat in a Mediterranean-type environment. I. The relation between yield, water use and climate. *Crop Pasture Sci.* 35 (6), 743–764.
- Guzzetti, F., Peruccacci, S., Rossi, M., Stark, C.P., Rainfall thresholds for the initiation of landslides in central and southern Europe. *Meteorol. Atmos. Phys.* 98 (3), 239–267.
- Hou, A.Y., Kakar, R.K., Neeck, S., Azbarzin, A.A., Kummerow, C.D., Kojima, M., Oki, R., Nakamura, K., Iguchi, T., The global precipitation measurement mission. *Bull. Am. Meteorol. Soc.* 95 (5), 701–722.
- Huffman, G.J., Adler, R.F., Arkin, P., Chang, A., Ferraro, R., Gruber, A., Janowiak, J., McNab, A., Rudolf, B., Schneider, U., The global precipitation climatology project (GPCP) combined precipitation dataset. *Bull. Am. Meteorol. Soc.* 78 (1), 5–20.
- Huffman, G.J., Adler, R.F., Bolvin, D.T., Nelkin, E.J., The TRMM multi-satellite precipitation analysis (TMPA). In: Satellite Rainfall Applications for Surface Hydrology. Springer, pp. 3–22.
- Iverson, R.M., Landslide triggering by rain infiltration. *Water Resour. Res.* 36 (7), 1897–1910.

- Jones, D.A., Wang, W., Fawcett, R., High-quality spatial climate data-sets for Australia. *Aust. Meteorol. Oceanogr. J.* 58 (4), 233.
- Jongman, B., Hochrainer-Stigler, S., Feyen, L., Aerts, J.C., Mechler, R., Botzen, W.W., Bouwer, L.M., Pflug, G., Rojas, R., Ward, P.J., Increasing stress on disaster-risk finance due to large floods. *Nat. Clim. Chang.* 4 (4), 264–268.
- Joyce, R.J., Janowiak, J.E., Arkin, P.A., Xie, P., CMORPH: A method that produces global precipitation estimates from passive microwave and infrared data at high spatial and temporal resolution. *J. Hydrometeorol.* 5 (3), 487–503.
- Kerr, Y.H., Waldteufel, P., Richaume, P., Wigneron, J.P., Ferrazzoli, P., Mahmoodi, A., Al Bitar, A., Cabot, F., Gruhier, C., Juglea, S.E., et al., The SMOS soil moisture retrieval algorithm. *IEEE Trans. Geosci. Remote Sens.* 50 (5), 1384–1403.
- Krajewski, W., Smith, J., Radar hydrology: rainfall estimation. *Adv. Water Resour.* 25 (8), 1387–1394.
- Lanza, L.G., Vuerich, E., The WMO field intercomparison of rain intensity gauges. *Atmos. Res.* 94 (4), 534–543.
- Lievens, H., Tomer, S.K., Al Bitar, A., De Lannoy, G., Drusch, M., Dumedah, G., Franssen, H.-J.H., Kerr, Y., Martens, B., Pan, M., et al., SMOS soil moisture assimilation for improved hydrologic simulation in the Murray Darling Basin, Australia. *Remote Sens. Environ.* 168, 146–162.
- Marsaglia, G., Tsang, W.W., A simple method for generating gamma variables. *ACM Trans. Math. Softw. (TOMS)* 26 (3), 363–372.
- Masson, V., Le Moigne, P., Martin, E., Faroux, S., Alias, A., Alkama, R., Belamari, S., Barbu, A., Boone, A., Bouyssel, F., et al., The SURFEX v7. 2. Land and ocean surface platform for coupled or offline simulation of earth surface variables and fluxes. *Geosci. Model Dev.* 6, 929–960.
- McColl, K.A., Alejomammad, S.H., Akbar, R., Konings, A.G., Yueh, S., Entekhabi, D., The global distribution and dynamics of surface soil moisture. *Nat. Geosci.* 10 (2), 100–104.
- Pellarin, T., Ali, A., Chopin, F., Jobard, I., Bergès, J.-C., Using spaceborne surface soil moisture to constrain satellite precipitation estimates over West Africa. *Geophys. Res. Lett.* 35 (2) L02813.
- Pellarin, T., Louvet, S., Gruhier, C., Quantin, G., Legout, C., A simple and effective method for correcting soil moisture and precipitation estimates using AMSR-e measurements. *Remote Sens. Environ.* 136, 28–36.
- Pellarin, T., Tran, T., Cohard, J.M., Galle, S., Laurent, J.P., De Rosnay, P., Vischel, T., Soil moisture mapping over West Africa with a 30-min temporal resolution using AMSR-e observations and a satellite-based rainfall product. *Hydrol. Earth Syst. Sci. Discuss.* 13 (10), 1887–1896.
- Pennington, C., Dijkstra, T., Lark, M., Dashwood, C., Harrison, A., Freeborough, K., Antecedent precipitation as a potential proxy for landslide incidence in South West United Kingdom. In: *Landslide Science for a Safer Geoenvironment*. Springer, pp. 253–259.
- Pielke, R.A., Avissar, R., Raupach, M., Dolman, A.J., Zeng, X., Denning, A.S., et al., Interactions between the atmosphere and terrestrial ecosystems: influence on weather and climate. *Glob. Chang. Biol.* 4 (5), 461–475.
- Plaza, A.D., De Keyser, R., De Lannoy, G., Giustarini, L., Matgen, P., Pauwels, V., The importance of parameter resampling for soil moisture data assimilation into hydrologic models using the particle filter. *Hydrol. Earth Syst. Sci.* 16 (2), 375–390.
- Prasetya, R., As-syakur, A.R., Osawa, T., Validation of TRMM precipitation radar satellite data over Indonesian region. *Theor. Appl. Climatol.* 112 (3–4), 575–587.
- Ramarohetra, J., Sultan, B., Baron, C., Gaiser, T., Gossel, M., How satellite rainfall estimate errors may impact rainfed cereal yield simulation in West Africa. *Agric. For. Meteorol.* 180, 118–131.
- Seneviratne, S.I., Koster, R.D., Guo, Z., Dirmeyer, P.A., Kowalczyk, E., Lawrence, D., Liu, P., Mocko, D., Lu, C.H., Oleson, K.W., et al., Soil moisture memory in AGCM simulations: analysis of global land-atmosphere coupling experiment (GLACE) data. *J. Hydrometeorol.* 7 (5), 1090–1112.
- Shannon, M.A., Bohn, P.W., Elimelech, M., Georgiadis, J.G., Marinas, B.J., Mayes, A.M., Science and technology for water purification in the coming decades. *Nature* 452 (7185), 301–310.
- Smith, A., Walker, J., Western, A., Young, R., Ellett, K., Pipunic, R., Grayson, R., Sriwardena, L., Chiew, F., Richter, H., The Murrumbidgee soil moisture monitoring network data set. *Water Resour. Res.* 48 (7).
- Sorooshian, S., Hsu, K.L., Gao, X., Gupta, H.V., Imam, B., Braithwaite, D., Evaluation of PERSIANN system satellite-based estimates of tropical rainfall. *Bull. Am. Meteorol. Soc.* 81 (9), 2035–2046.
- Van Asch, T.W., Buma, J., Van Beek, L., A view on some hydrological triggering systems in landslides. *Geomorphology* 30 (1), 25–32.
- Wake, B., Flooding costs. *Nat. Clim. Chang.* 3 (9), 778.
- Wanders, N., Pan, M., Wood, E., Correction of real-time satellite precipitation with multi-sensor satellite observations of land surface variables. *Remote Sens. Environ.* 160, 206–221.
- Yan, H., DeChant, C.M., Moradkhani, H., Improving soil moisture profile prediction with the particle filter-Markov chain Monte Carlo method. *IEEE Trans. Geosci. Remote Sens.* 53 (11), 6134–6147.
- Yilmaz, M.T., Crow, W.T., The optimality of potential rescaling approaches in land data assimilation. *J. Hydrometeorol.* 14 (2), 650–660.
- Yin, X., Gruber, A., Validation of the abrupt change in GPCP precipitation in the Congo river basin. *Int. J. Climatol.* 30 (1), 110–119.

**F.1.4 Gibon et al. 2017 : Crop yield monitoring in the Sahel using SMOS satellite derived soil moisture time series**

in review...



## F.2 Conférences/Workshop

### F.2.1 Gibon et al. 2015, *SMOS Assimilation into SURFEX Land Surface Model : Application to Crop Yield Estimate in West Africa*, ESA 2nd SMOS Science, El Escorial (Espagne), poster

\*\*\*\*\*

#### Poster 26

##### **Improvements to the Use of Satellite Soil Moisture Measurements in an Operational Land Data Assimilation System**

Candy, B.

Met Office (United Kingdom)

The Met Office runs as a land data assimilation scheme, as part of the operational NWP suite, principally to provide an updated soil moisture analysis. Satellite estimates of near surface soil moisture are a critical observational dataset for this scheme. An important aspect of satellite usage is the conversion of the satellite retrieval to an equivalent value that represents the near surface soil moisture. In this poster we will examine the impact of updating this method of conversion for ASCAT via a new climatology generated from the latest version of the JULES land surface model, with updated soil parameters. SMOS level 2 data will be used as an independent assessment of the resulting soil moisture analyses. In addition future improvements to the land data assimilation scheme will be presented, such as plans to test the impact of SMOS data and improved treatment of observation errors.

\*\*\*\*\*

#### Poster 27

##### **SMOS Assimilation into SURFEX Land Surface Model: Application to Crop Yield Estimate in West Africa**

Gibon, F.<sup>1</sup>; Pellarin, T.<sup>1</sup>; Baron, C.<sup>2</sup>; Traoré, S.<sup>3</sup>; Leroux, D.<sup>1</sup>; Kerr, Y<sup>4</sup>;

<sup>1</sup>LTHE (France), <sup>2</sup>CIRAD (France), <sup>3</sup>AGRHYMET (Nigeria), <sup>4</sup>CESBIO (France)

#### INTRODUCTION

In West-Africa, land surface modelling (LSM) suffers from strong uncertainties related to the precipitation rate. The low density of the rain gauge network associated with almost no weather radar in this area imposes the use of satellite-based precipitation products which are known to be particularly inaccurate quantitatively. Consequently, LSM outputs exhibits some large discrepancies with in-situ soil moisture and associated fluxes. To improve land surface simulations, a solution lies in

assimilating surface soil moisture estimates from the SMOS satellite. In a recent paper, Louvet et al. (2014) show that surface soil moisture simulated with a simple one-layer model (5 cm depth) can be strongly improved using SMOS measurements in West Africa. In the present paper, the methodology is applied to a more sophisticated land surface model (SURFEX from Meteo-France) in order to observe the benefit on both the root-zone soil moisture and the associated sensible and latent fluxes.

#### METHOD

SURFEX is a physical surface modelling platform designed to represent the surface processes exposed to an atmospheric forcing. The option ISBA-DIF allows a soil multi-layer simulation of a natural area. A first simulation is done at the West Africa scale (0.25° resolution) for the 2010-2013 period. Then, SMOS soil moisture product (L3SM) is assimilated into the SURFEX model using a Kalman filter scheme. Outputs of both simulations are compared together and assessed using in-situ data provided by the AMMA-CATCH observatory. Finally, an attempt to link soil moisture profiles with measured crop production is done in the Niamey region in Niger.

#### RESULTS & DISCUSSION

LSM results show some differences whether SMOS is used or not. Main differences concern the spatial distribution as well as the water infiltration depth. These two characteristics are closely linked to the crop production since the soil water content is the main limitation of the plant growth in this region. Crop measurements were obtained over 10 farms located in the Niamey region in Niger from 2005 to 2012. The mean production (8 years) is 690 kg/ha, and was equal to 765/381/506 kg/ha in 2010/2011/2012 respectively.

Most studies dedicated to crop monitoring are based on thermal infrared (e.g. MODIS) or rainfall measurements (e.g. CMORPH). Here, we focus on the soil water content which is the main limitation to crop production.

\*\*\*\*\*

#### Poster 28

##### **SMOS and Long Term Soil Moisture Comparison. Study over the Iberian Peninsula**

Portal, G.<sup>1</sup>; Vall-llossera, M.<sup>2</sup>; Chaparro, D.<sup>2</sup>; Piles, M.<sup>2</sup>; Camps, A.<sup>2</sup>; Pablos, M.<sup>2</sup>; Pou, X.<sup>2</sup>



2nd SMOS SCIENCE CONFERENCE - 25-29 May 2015, ESA-ESAC (near Madrid), Spain



## SMOS assimilation into SURFEX land surface model :

### Application to crop yield estimate in West Africa

François Gibon<sup>1\*</sup>, Thierry Pellarin<sup>1</sup>, Christian Baron<sup>2</sup>, Seydou Traoré<sup>2</sup>

<sup>1</sup> LTHE, Grenoble, \*francois.gibon@ujf-grenoble.fr

<sup>2</sup> CIRAD, Montpellier



#### Introduction - background

Crop yield is closely related to the soil water content, especially in the root-zone. In order to estimate this quantity, it is needed to represent as well as possible the precipitation rate. However, in some vulnerable area as West Africa, the low density of the rain gauge network ( $1/10000 \text{ km}^2$ ) makes this water input hard to represent. A common solution is to use Land Surface Model (LSM) coupled with satellite precipitation products, yet know to be inaccurate quantitatively. It is possible to reduce these uncertainties by forcing the LSM to assimilate surface soil moisture estimates from SMOS (Soil Moisture and Ocean Salinity) observations.

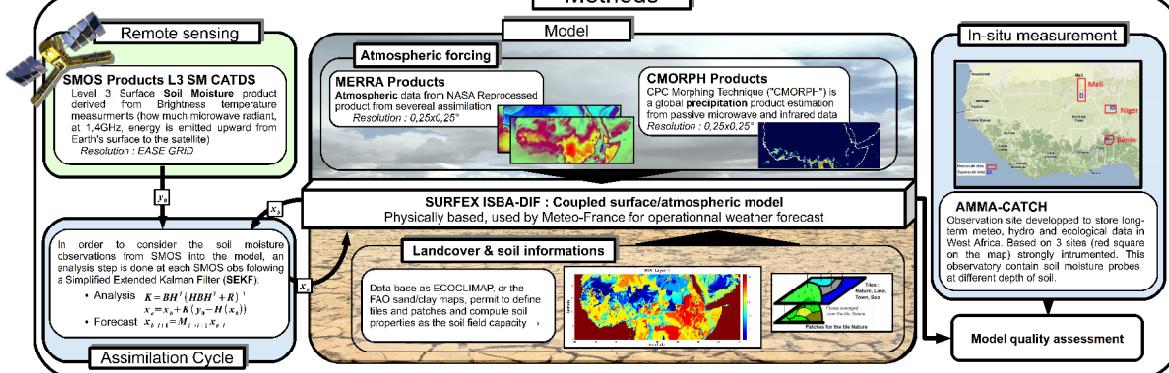
#### Objectives

Process hourly soil moisture West-Africa maps at  $0.25^\circ \times 0.25^\circ$  for several soil depths from LSM (SURFEX-ISBA DIF) assimilated with SMOS Soil Moisture products

↓ What is the impact of assimilation on the root-zone soil moisture ?

↓ How the space-time variation of soil moisture impact the crop yield ?

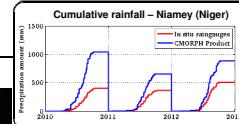
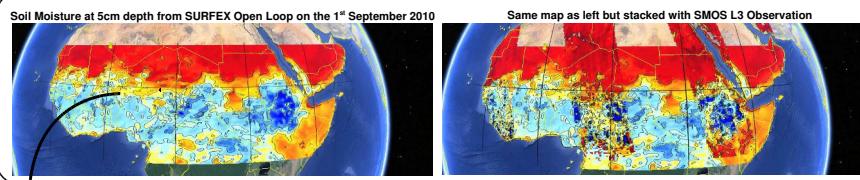
#### Methods



#### Results & Discussions

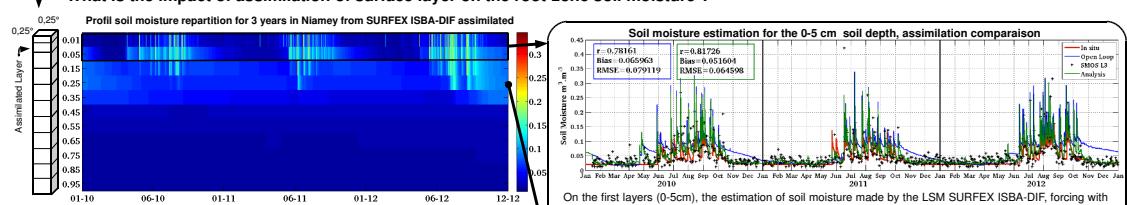
##### • Process hourly soil moisture West-Africa maps for several soil depths from LSM (SURFEX) assimilated with SMOS Soil Moisture products :

What is the spatial distribution difference between LSM and the SMOS Obs ?



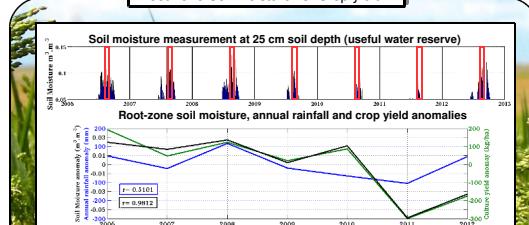
↑ The difference between the two cumulative rainfall is a strong quantitative error of the satellite products, setting the model without soil moisture observation leads to inaccurate soil moisture estimation.  
← The difference between the two maps shows that even if the global trend is kept, the spatial distribution is much more contrasted in the SMOS observations.

##### • What is the impact of assimilation of surface layer on the root-zone soil moisture ?

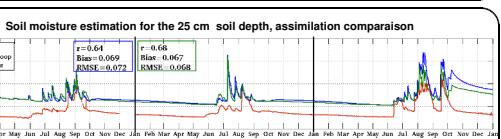


On the first layers (0-5cm), the estimation of soil moisture made by the LSM SURFEX ISBA-DIF, forcing with MERRA atmospheric products and CMORPH rains products shows a good approximation in Open-Loop (blue line), and even better assimilation (green line) of SMOS L3 products (black cross, after CDF matching). The SMOS assimilation trend to dry the model and correct the infiltration slope.

##### Root zone Soil moisture vs. Crop yield ?



Crop yield is mainly limited by water in West Africa. As the figure above shows, the link between soil moisture anomalies, in the useful water reserve of the root zone (~25cm) during the period of half August – September, and the anomalies of culture yield (CIRAD data around the 1<sup>st</sup> square of Niamey) is significant compare to the link with the annual rainfall anomalies.



On the 25cm layer, the estimation of soil moisture is biased but the dynamic dry/wet is respected. The dates of start and end of the infiltration are correct (unless for the end of 2012 because of CMORPH rains does not saw in in-situ). The SMOS assimilation improve the estimation by drying the soil.

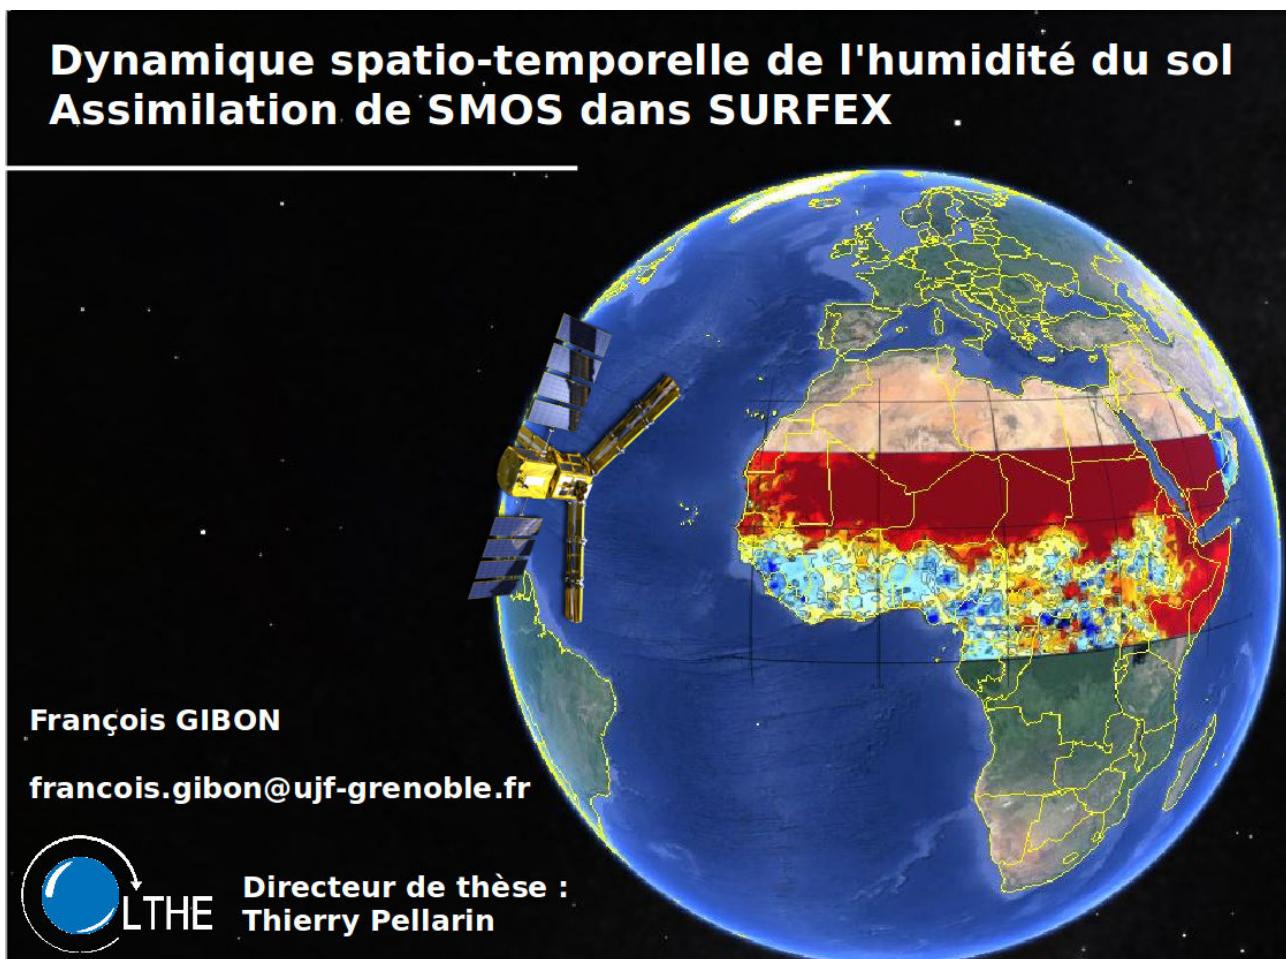
#### Summary & conclusion

Surface soil moisture estimation in West Africa can be improved by SMOS observation assimilation (Louvet et al. 2014). In the present study the assimilation is done in a multilayer LSM. The result of this assimilation shows a significant correction in surface layers and an improvement in the root-zone. By assimilate the SMOS observation it is expected to provide a better soil moisture spatial variability. In West-Africa, the root-zone soil moisture tends to be directly linked to the agricultural yield, a correct representation of this available water seems interesting to monitor crop yield.

- F.2.2 Gibon et al. 2015, *Modélisation de l'humidité du sol en assimilant des données satellitaires (SMOS) dans un modèle de surface (SURFEX) en Afrique de l'Ouest*, Réunion ORE AMMA-CATCH, Sète (France), poster

Même poster que précédemment.

- F.2.3 Gibon et al. 2015, *Assimilation du produit L3SM SMOS dans le modèle de surface SURFEX en région sahélienne*, Workshop Modélisation de surface, CESBIO Toulouse (France), oral



F.2.4 Gibon et al. 2016, *SMOS Assimilation into SURFEX Land Surface Model : Application to Sahelian Crop Yield Estimation*, ESA Living Planet Symposium, Pragues (République Tchèque), poster

---

[[Authors](#)] [[Overview programme](#)] [[Keywords](#)]

Paper 1955 - Session title: *Land Posters*

**LAND-216 - SMOS assimilation into SURFEX land surface model: Application to Sahelian crop yield estimation**

Gibon, François (1); Pellarin, Thierry (1); Baron, Christian (2); Lo Seen, Danny (2) 1: Laboratoire d'étude des Transferts en Hydrologie et Environnement (LTHE), Grenoble, France; 2: Centre de coopération Internationale en Recherche Agronomique pour le Développement (CIRAD), Montpellier, France

[Hide abstract](#)

The Sahel is a semiarid region south of the Sahara Desert that stretches from the Atlantic Ocean to the Red Sea. Mainly based on rainfed agriculture, the Sahelian region is known to be quite vulnerable to climate change and precipitation variability. In this context, national and regional institutions are interested in getting soil wetness conditions at the regional scale in order to derive/forecast crop yield estimations. To fulfill this objective, classical methods are based on daily precipitation measurements from the raingauge network, however, they suffer from the poor density raingauge network in Africa.

An alternative strategy is to use Land Surface Models (LSM) designed to determine multi-layer soil moisture conditions and related fluxes in response to atmospheric forcing. In this study, we performed soil moisture maps over the Sahelian region using the SURFEX LSM from Meteo-France, at the 0.25° resolution for the 2010-2013 period. First simulations showed that LSM outputs exhibited some large discrepancies with in-situ soil moisture measurements and associated fluxes when satellite precipitation products are used instead of in situ precipitation measurements. Moreover, LSM outputs were also found to be rather different according to the precipitation product forcing used in the LSM model (CMORPH, PERSIANN or TRMM-3B42).

In this study, it was proposed to constrained LSM soil moisture simulations with satellite soil moisture measurements provided by the SMOS (Soil Moisture and Ocean Salinity) mission. SMOS is a L-band radiometer using aperture synthesis and was successfully launched by the European Space Agency (ESA) on November 2, 2009. SMOS soil moisture product (L3SM) was assimilated into the SURFEX model using a Simplified Extended Kalman Filter (SEKF) scheme. Outputs of LSM+SMOS simulations were found to be in much better agreement with in situ soil moisture measurements. Another significant result deals with the soil moisture spatial distribution of the LSM+SMOS simulations which was found to be closely linked to the SMOS soil moisture variability.

These two characteristics (accuracy and spatial distribution of soil moisture) are closely related to the crop production since the soil water content is the main limitation of the plant growth in this region. Crop yield measurements were obtained over 10 farms located in the Niamey region in Niger from 2005 to 2012. The mean production (8 years) is 690 kg/ha, and ranges from 381 to 872 kg/ha during this period. Various statistical relationships based on soil moisture estimates were tested and the most promising one rely soil moisture anomalies from mid-August to mid-September in the root zone with crop yield anomalies. The statistical relationship provides an estimation of the crop yield with a correlation coefficient of R=0.98 using in situ soil moisture measurements. This result will be extended to the whole Sahelian region and compare to other ground-based crop yield measurements in Burkina Faso.

## SMOS assimilation into SURFEX land surface model: Application to Sahelian crop yield estimation



François Gibon<sup>1</sup>, Thierry Pellarin<sup>1</sup>, Christian Baron<sup>2</sup>, Danny Lo Seen<sup>2</sup>, Seydou Traore<sup>2</sup>

<sup>1</sup>LTHE, Grenoble, France, \*francois.gibon@ujf-grenoble.fr

<sup>2</sup> CIRAD, Montpellier, France

### Introduction - background

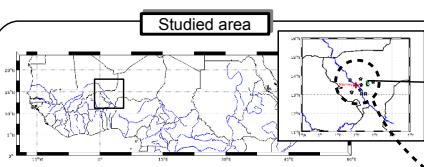
Mainly dependant on rainfed agriculture, the Sahelian region is known to be vulnerable to climate change and particularly to precipitation variability. In this context, national and regional institutions are interested in obtaining all wetness conditions at the regional scale in order to derive/forecast crop yield estimation. To fulfil this objective, classical methods are based on daily precipitation measurements from the raingauge network. However, they suffer from the poor density of the raingauge network in Africa ( $1/10000 \text{ km}^2$ ). In this study we propose using one rainfall-proxy, soil moisture, in order to identify a relation with crop yields. First, the spatio-temporal scale variations of soil moisture anomalies is characterised in order to define the most relevant scale for representing crop yield anomalies, then the representation of soil moisture variation is addressed.

### Questions

- How does the space-time variation of soil moisture impact crop yield ?

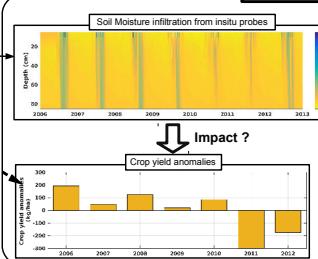
- How to represent these soil moisture variations at a large scale ?

### Methods



The Sahelian region is well known for its strong climatic gradient (from tropical to arid climate), its high rainfall variability and its strong radiance. These properties induce a strong impact of soil moisture on the water/energy/carbon balance. The specific area of this study is located around Niamey, the capital of Niger. This area have been strongly instrumented in recent decades, thanks to the AMMA program. Long term surveys of crop yields for the surrounding villages are also available.

#### SM vs Crop Yield ?



AMMA CATCH Observatory has been developed to store long-term meteo, hydro and ecological data in West Africa. Based on 3 sites (Benin, Mali, Niger) strongly instrumented, this observatory contains soil moisture probes at different depths. The figure on the left represents the evolution of the soil moisture profile in Niger.

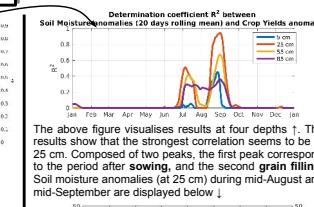
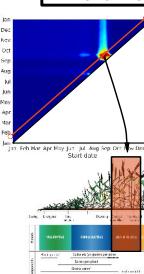
Millet yield values have been collected for 10 villages around Niamey (black stars on the left map). Here are the mean annual values. Quantities looks stable from 2006 to 2010, then drop dramatically during the 2011 drought and improve slightly the next year.

### Results & Discussions

- How does the space-time variation of soil moisture impact crop yield ?

In order to determine the most influential period of soil wetness anomaly, a rolling mean is computed over 7 years at 4 different depths (5, 25, 55, 85 cm). Results are resumed on the figure on the top right. This figure represents the determination coefficient ( $R^2$ ) between the soil moisture anomalies and the crop yield anomalies. The beginning of the time window is on the x-axis, and the y-axis represents the end of the window. A spot is strongly marked between mid-August and end of September, which corresponds to the period of grain filling →

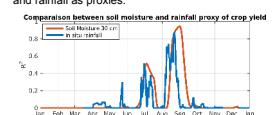
#### When & where ?



The above figure visualizes results at four depths. The results show that the strongest correlation seems to be at 25 cm. Composed of two peaks, the first peak correspond to the period after sowing, and the second grain filling. Soil moisture anomalies (at 25 cm) during mid-August and mid-September are displayed below ↓

#### What about rain ?

Rainfall products are often used to derive crop yield estimates. However, due to its high spatio-temporal variability and high frequency, this processus is complex to represent. The graph below compares the crop yield estimation quality between soil moisture and rainfall as proxies.

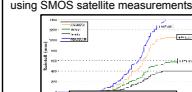


Even if the maximum determination coefficient is almost the same ( $R^2=0.9$ ), the time stability of soil moisture is a strong advantage. Soil moisture reacts as a low-pass filter and takes into account only the precipitation portion which is available for plants..

- How to represent these soil moisture variations at a large scale ?

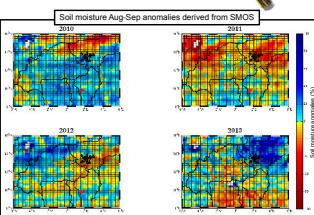
#### Modellisation

Models suffer from high uncertainties of forcing, especially rainfall with regard to soil moisture. A solution is to use an assimilation system to constrain the model using SMOS satellite measurements.

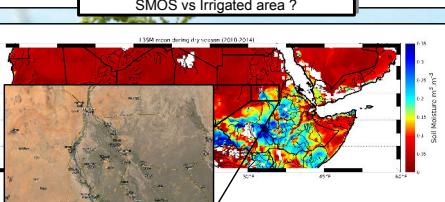


#### Microwave Remote Sensing

Another way to estimate soil moisture is to directly use microwave remote sensing, as the satellite SMOS. The main difficulty is the depth of estimation which is considered around 5 cm depth. However, the anomalies computed directly from the SMOS L3SM product, for the period define above seem give a real idea of the crop yield state.



#### SMOS vs Irrigated area ?



By analysing the mean soil moisture estimated from the L3SM SMOS during the dry season (Nov → Feb), some patterns appear much wetter. These patterns can be due to topography, vegetation effect, ... or irrigated areas such as the Khartoum area (Sudan) !

### Summary & conclusion

• Soil moisture anomalies is promising as a first-order approach to consider crop yield anomalies. The period highlighted in this study is mid-August to mid-September. During this period, which correspond to the grain filling period, crop yield appears particularly sensitive to the soil moisture deficit ( $R>0.9$ ). The same approach was conducted with rainfall, which gives lower correlation.

• To spatialize this approach, several solutions exist. First, anomalies directly derived from microwave remote sensing appears consistent and features strong spatial heterogeneity. However the one-point study shows better results at 25 cm than at 5 cm. To reach this depth, a Land Surface Model, SURFEX, constrained by remotely sensed soil moisture to correct forcing uncertainties, is being processed.

**F.2.5 Gibon et al. 2017, *Crop yield Monitoring in the Sahel using root zone soil moisture anomalies derived from SMOS soil moisture data assimilation*, EGU General Assembly, Vienne (Autriche), oral**

Geophysical Research Abstracts  
Vol. 19, EGU2017-6315-1, 2017  
EGU General Assembly 2017  
© Author(s) 2017. CC Attribution 3.0 License.



**Crop yield monitoring in the Sahel using root zone soil moisture anomalies derived from SMOS soil moisture data assimilation**

François Gibon (1), Thierry Pellarin (1), Agali Alhassane (2), Seydou Traoré (2), and Christian Baron (3)  
(1) Univ. Grenoble Alpes, CNRS, IRD, Grenoble INP, IGE, F-38000 Grenoble, France, (2) AGRYMHET Regional Center, BP 11011 Niamey, Niger, (3) Centre de coopération internationale en recherche agronomique pour le développement, CIRAD, Montpellier, France

West Africa is greatly vulnerable, especially in terms of food sustainability. Mainly based on rainfed agriculture, the high variability of the rainy season strongly impacts the crop production driven by the soil water availability in the soil. To monitor this water availability, classical methods are based on daily precipitation measurements. However, the raingauge network suffers from the poor network density in Africa (1/10000km<sup>2</sup>). Alternatively, real-time satellite-derived precipitations can be used, but they are known to suffer from large uncertainties which produce significant error on crop yield estimations.

The present study proposes to use root soil moisture rather than precipitation to evaluate crop yield variations. First, a local analysis of the spatiotemporal impact of water deficit on millet crop production in Niger was done, from in-situ soil moisture measurements (AMMA-CATCH/OZCAR (French Critical Zone exploration network)) and in-situ millet yield survey. Crop yield measurements were obtained for 10 villages located in the Niamey region from 2005 to 2012. The mean production (over 8 years) is 690 kg/ha, and ranges from 381 to 872 kg/ha during this period. Various statistical relationships based on soil moisture estimates were tested, and the most promising one ( $R>0.9$ ) linked the 30-cm soil moisture anomalies from mid-August to mid-September (grain filling period) to the crop yield anomalies.

Based on this local study, it was proposed to derive regional statistical relationships using 30-cm soil moisture maps over West Africa. The selected approach was to use a simple hydrological model, the Antecedent Precipitation Index (API), forced by real-time satellite-based precipitation (CMORPH, PERSIANN, TRMM3B42). To reduce uncertainties related to the quality of real-time rainfall satellite products, SMOS soil moisture measurements were assimilated into the API model through a Particular Filter algorithm. Then, obtained soil moisture anomalies were compared to 17 years of crop yield estimates from the FAOSTAT database (1998-2014). Results showed that the 30-cm soil moisture anomalies explained 89% of the crop yield variation in Niger, 72% in Burkina Faso, 82% in Mali and 84% in Senegal.

**F.2.6 Román-Cascón et al. 2017, *Correcting satellite-based precipitation products from SMOS soil moisture data assimilation using two models of different complexity*, EGU General Assembly, Vienne (Autriche), oral**

Geophysical Research Abstracts  
Vol. 19, EGU2017-5324, 2017  
EGU General Assembly 2017  
© Author(s) 2017. CC Attribution 3.0 License.



**Correcting satellite-based precipitation products from SMOS soil moisture data assimilation using two models of different complexity**

Carlos Román-Cascón, Thierry Pellarin, and François Gibon  
Univ. Grenoble Alpes, CNRS, IRD, Grenoble INP, IGE, F-38000 Grenoble, France

Real-time precipitation information at the global scale is quite useful information for many applications. However, satellite-based precipitation products in real time are known to be biased from real values observed in situ. On the other hand, the information about precipitation contained in soil moisture data can be very useful to improve precipitation estimation, since the evolution of this variable is highly influenced by the amount of rainfall at a certain area after a rain event. In this context, the soil moisture data from the Soil Moisture Ocean Salinity (SMOS) satellite is used to correct the precipitation provided by real-time satellite-based products such as CMORPH, TRMM-3B42RT or PERSIANN. In this work, we test an assimilation algorithm based on the data assimilation of SMOS measurements in two models of different complexity: a simple hydrological model (Antecedent Precipitation Index (API)) and a state-of-the-art complex land-surface model (Surface Externalisée (SURFEX)). We show how the assimilation technique, based on a particle filter method, leads to the improvement of correlation and root mean squared error (RMSE) of precipitation estimates, with slightly better results for the simpler (and less expensive computationally) API model. This methodology has been evaluated for six years in ten sites around the world with different features, showing the limitations of the methodology in regions affected by mountainous terrain or by high radio-frequency interferences (RFI), which notably affect the quality of the soil moisture retrievals from brightness temperatures by SMOS. The presented results are promising for a potential near-real time application at the global scale.

# ABSTRACT

---

Soil moisture was declared Essential Climate Variable (ECV) in 2010 by the European Space Agency (ESA) in support of the work of the Intergovernmental Panel on Climate Change (IPCC). In vulnerable areas such as West Africa (poorly irrigated and subsistence agriculture, extreme temperatures and high variability of rainfall), the added value of informations on soil moisture is important, especially in a changing climate. The first part of this thesis concerns the representation of root-zone soil moisture on a large scale using the triptych in-situ measurements/remote sensing/modeling. These 3 methods each have limitations : (i) the low density of in-situ networks (3 measurement sites throughout West Africa), (ii) SMOS estimates only at the surface (0-5 cm) and (iii) the uncertainties of the real-time precipitation forcing used in surface models. In order to reduce these limitations, an assimilation method (particle filter) of SMOS data has been implemented in an empirical surface model (API) and compared to AMMA-CATCH in-situ measurements. The results show an improvement of the humidities modeled after assimilation. The second part concerns the impact of soil moisture variations on millet yields. A statistical relationship was first determined from yield data measured in 10 villages around Niamey. The results show that the 20-day soil moisture anomalies at the beginning of July and the end of August - mid September (reproductive period and grain filling period), at a depth of 30 cm, explain the variations in yield measured at  $R^2=0.77$ . This relationship was then applied to the Nigerien scale from FAO yield data and in-depth moisture maps developed in the first part of the thesis. The results show a correlation of  $R^2=0.62$  over the years 1998-2014. Then, the method was apply to 3 other sahelian countries, showing a agreement of  $R^2=0.77$ . The last part of this work concerns the exploitation of the residuals of the assimilation scheme in order to reduce the uncertainties on the precipitations. The satellite precipitation products CMORPH, TRMM and PERSIANN, in their real-time version, were compared to rain gauges before and after assimilation. The result of this study shows a marked improvement in the estimated precipitations intensities. The method was then applied to a precipitation product used at the AGRHYMET regional center for agricultural monitoring, the TAMSAT product.

This thesis work has led to further research into the potential of satellite moisture data for agronomic applications. The perspectives of this work mainly concern : (i) the use of other sensors (SMAP, ASCAT, AMSR) to increase the frequency of the observations of humidity in the assimilation, (ii) on methods of disaggregation of the coefficients for the correction of precipitation at higher spatial resolution and (iii) the use of multispectral data (vegetation indices, soil temperature, ...) for better monitoring of yields.

**Keywords :** Soil moisture, precipitation, SMOS, assimilation, agronomy, West Africa, FAO