



HAL
open science

Synergie des données satellitaires optiques et radar pour l'étude des zones côtières inondables à l'ouest algérien

Narimane Zaabar

► To cite this version:

Narimane Zaabar. Synergie des données satellitaires optiques et radar pour l'étude des zones côtières inondables à l'ouest algérien. Hydrologie. Université de Bretagne occidentale - Brest; Ecole nationale supérieure de l'hydraulique (Blida (Algérie)), 2022. Français. NNT : 2022BRES0089 . tel-04373353

HAL Id: tel-04373353

<https://theses.hal.science/tel-04373353>

Submitted on 5 Jan 2024

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.



THESE DE DOCTORAT EN COTUTELLE INTERNATIONALE DE

L'UNIVERSITE
DE BRETAGNE OCCIDENTALE, FRANCE

ECOLE DOCTORALE N° 598
Sciences de la Mer et du littoral
Spécialité : *Géomatique*

Et
ECOLE NATIONALE SUPERIEURE
DE L'HYDRAULIQUE, ALGERIE

Spécialité : *Hydraulique*

Par

Narimane ZAABAR

**Synergie des données satellitaires optiques et radar pour l'étude des
zones côtières inondables à l'ouest algérien**

Thèse présentée et soutenue à Plouzané, le 14/12/2022

Unité de recherche : LETG Brest- UMR 6554 CNRS

Rapporteurs avant soutenance :

Thomas CORPETTI, Directeur de recherche CNRS, Université de Rennes 2
Cherifa ABDELBAKI, Professeur, Université de Tlemcen, Algérie

Composition du Jury :

Président : Sébastien GADAL Professeur, Aix-Marseille Université

Examineurs : Thomas CORPETTI Directeur de recherche CNRS, Université de Rennes 2
Cherifa ABDELBAKI Professeur, Université de Tlemcen, Algérie
Bernard POTTIER Professeur, Université de Bretagne Occidentale

Directeurs de thèse :

Simona NICULESCU
Mustapha Kamel MIHOUBI

Maitre de conférence HDR, Université de Bretagne Occidentale
Professeur, Ecole Nationale supérieure de l'Hydraulique, Algérie

إذا كنت في الطريق إلى الله فاركض
وان صعب عليك فمهول
وان تعبت فامش فان لم تستطع فسير هبوا
واياك والرجوع
الإمام الشافعي

إلى هـما وهـو...

على سطح منزلها، تحت نور بدر مكتمل تجلّى بمحاذاة أوراسي الجميل.. ابتداءً الظلم!
إليها.. بالأحرى إلى روحها التي توفف عندها الثغر في يوليو الأضير ففار قنني في منتصف معركتي..

إليك جبرتي فطيرة أهدي تفاصيل هذا الظلم

..

إليه.. كلّي ولياني، روح مرافقة، مؤمنة بي، روح قدمت لي قلبا وربلا لن يكرره الزمن مرتين..
إليك شعيب أهدي تتره صلمي الذي لم يكن ليكبر ويكتمل اليوم إلا بك

..

إليك ديمها فرح.. بعبرات فرح وألم ربما
أهدي لك إجازك الذي كنت جزءا فيه.. فقبل سنتين ونصف ابتدأت رحلة عظيمة كنت أنت طوق النجاة فيها..
كنت الصافية والرفيقة وروحا من نور باركنني فكان التيسير والتسهيل صليفي

..

اليوم اكتمل البدر قمرا جميلا مضيئا.. وبكم انتصرت!

ناريمان

براست.. تشرين الأول 2022

REMERCIEMENT

J'aimerais tout d'abord remercier chaleureusement ma directrice de thèse, Simona NICULESCU, enseignante chercheuse au laboratoire LETG-Brest (France). Qu'elle trouve ici l'expression de ma plus sincère reconnaissance pour sa disponibilité, son soutien et sa confiance qu'elle m'a accordée pour mener ces travaux de recherche. Qu'elle voie dans cette recherche un témoignage de toute mon estime.

Mes remerciements sont également destinés à mon directeur de thèse, Mustapha Kmel MIHOUBI, professeur à l'Ecole Nationale Supérieure de l'Hydraulique (Algérie) pour son soutien, sa rigueur, ses efforts considérables ainsi que sa disponibilité et ses nombreux conseils durant les travaux de ma thèse.

J'adresse tous mes remerciements à Madame, Cherifa ABDELBAKI, Professeur à l'Université de Tlemcen (Algérie), ainsi qu'à Monsieur Thomas CORPETTI, directeur de recherche à l'université Rennes 2, de l'honneur qu'ils m'ont fait en acceptant d'être rapporteurs de cette thèse.

J'exprime ma gratitude à Monsieur Sébastien GADAL et à Monsieur Bernard POTTIER, qui ont bien voulu être examinateurs.

Ce travail n'aurait pas été possible sans l'environnement de travail chaleureux au laboratoire de recherche LETG-Brest, qui m'a permis de me consacrer sereinement à l'élaboration de ma thèse durant 3 ans de recherche. Je remercie vivement tout le personnel de LETG et particulièrement le directeur de laboratoire, Cyril TISSOT, l'EX-directeur également, Serge SAUNEZ pour leur gentillesse et leur disponibilité, mes Co-bureau Aneta, Eugénie et Pauline, pour les belles discussions le long de la période que nous avons partagé ensemble, notre gentil informaticien Mathias, Julie et Isabelle.

Je tiens à témoigner toute ma reconnaissance et mes vifs remerciements à Laurence DAVID, pour avoir relu et corrigé ma thèse. Ses conseils de rédaction ont été très précieux.

Je remercie également l'équipe pédagogique de l'école doctorale des Sciences de la Mer et du Littoral (SML), en particulier mesdames Elisabeth et Aurélie pour la qualité de travail et leurs interventions professionnels responsables de mon dossier doctoral.

Enfin, Ce travail n'aurait pas été possible sans le soutien de ma famille, mes proches et mes amies. Je n'oublie jamais les sacrifices de mes chers parents depuis que j'ai été toute petite, mes chers frères et sœurs : Nesrine, Amar, Youcef et Yasmine, mes beaux-parents et toute la famille Zaabar et Belkhiri.

Je voudrais exprimer ma reconnaissance envers les amis et les personnes qui m'ont apporté leur soutien moral et intellectuel tout au long de mon parcours de doctorat, Un grand merci à mon AMIE Sirine KERKOUB pour ses encouragements et son soutien absolu depuis mon premier pas de mon séjour en France.

Mes remerciements particuliers vont également à ma chère Nadia SAYAH pour sa présence et son aide précieuse tout au long de mon séjour à Brest, mes chères amies Docteures Sarra MEHAMEL, Rania BOUSSEKINE et Dalal LALA BOUALI pour leurs conseils et leur soutien inestimable.

Enfin, Je tiens à témoigner toute ma reconnaissance aux personnes qui m'ont toujours encouragé, et à qui je souhaite tout le succès.

LISTES DES FIGURES

Figure I. 1. Différentes types d'inondation en Algérie.	29
Figure I.2. Visualisation d'une géométrie construite par un modèle 1D (Pons et al., 2014). ..	35
Figure I.3. Visualisation d'un modèle 2D (Marant, 2009).	35
Figure I.4. Visualisation d'un couplage 1D/2D (Marant, 2009)	36
Figure I. 5. Illustration de la méthode de calcul de la vulnérabilité en fonction des aléas (Solin et Skubincan, 2013).	41
Figure I.6. Méthode d'évaluation du risque d'inondation absolue - dommage en fonction de la probabilité (FLOODsite 2006).	43
Figure I.7. Exemple d'une caractérisation spatiale de l'inondation du Mississippi et du Missouri en 1993 à partir d'une Image Landsat 5 TM (avant et pendant les inondations) (NASA/EO, 2005).	46
Figure II. 1. Fonctionnement des systèmes de télédétection active et passive (E : Rayonnement, T: Transmis, R : Réfléchi, A : Absorbé, D : Diffusé).	59
Figure II. 2. Chronologie des mises en service et heures de fonctionnement des satellites optiques et radar d'observation de la Terre. La longueur de la flèche représente la continuité et la durée du programme satellite correspondant (Rumiano, 2021).	60
Figure II.3. Stations des programmes spatiaux Landsat 5 et 7.	64
Figure II.4. Historique des capteurs Radar de 1991 jusqu'à 2020 (UNAVCO, 2018).	68
Figure II.5. Les modes d'acquisitions de Sentinel-1(Sentinel-1 SAR Technical Guide (ESA).	69
Figure II. 6. Exemple d'un SVM (adaptée de (Burges, 1998).	79
Figure III.1. Localisation de premier site d'étude (Ain Témouchent, ouest algérien).	90
Figure III.2. Localisation de deuxième site d'étude (Région de Ténès, wilaya de Chlef, Ouest Algérien)	92
Figure III.3. Constellation des Pléiades 1A/1B et des SPOT 6/7.	96
Figure III.4. Composition colorée (RGB) d'un sous-ensemble couvrant la partie sud-ouest du centre-ville de Ain Témouchent : A droite : Image Pléiades, à gauche : image Sentinel-2.	98
Figure III.5. Satellite ALOS avec ses différents instruments (y compris le capteur actif PALSAR).	100
Figure III.6. Capacité tri-stéréoscopique de satellite Pléiades (Airbus, 2022).	101
Figure III.7. Localisation et délimitation de bassin versant étudié (Oued Allala- wilaya de Chlef).	102
Figure III.8. Carte hypsométrique du bassin versant Oued Allala.	104
Figure III.9. Courbe hypsométrique du bassin d'oued Allala.	104
Figure III.10. Carte géologique du bassin versant d'Oued Allala.	106

Figure IV.1. Interface de logiciel SNAP	110
Figure IV.2. Indice de végétation par différence normalisée (NDVI) calculé par les bandes de Sentinel-2 (région de Ténès).	114
Figure IV.3. Indice de la teneur en eau par différence normalisée (NDWI) calculé par les bandes de Sentinel-2 (région de Ténès).	115
Figure IV.4. Indice d'urbanisation par différence normalisée (NDBI) calculé par les bandes de Sentinel-2 (région de Ténès).	115
Figure IV.5. Sous ensemble de l'image provenant de la fusion optique et radar (Sentinel-1 et Sentinel-2).	116
Figure IV. 6. Méthodologie employée pour la classification de l'occupation du sol en utilisant l'approche synergique des données optiques et radar.	117
Figure IV.7. Exemples de classes d'occupation du sol définies	119
Figure IV.8. Segmentation Multi-résolution d'une image Pléaïdes à différentes valeurs de paramètre échelle.	121
Figure IV.9. Organigramme descriptif de classification de l'occupation du sol par la méthode CNN-OBIA.	124
Figure IV.10. Architecture de modèle CNN générée à partir de l'image Pléaïdes.	125
Figure IV.11. Architecture de modèle CNN générée à partir de l'image Sentinel-2.	126
Figure IV.12. Organigramme de la méthodologie proposée pour la classification et l'évaluation des changements de l'occupation du sol du bassin versant de l'Oued Allala.	129
Figure IV.13. Sous ensemble 1 (Ain Témouchent centre) de la carte d'occupation du sol à partir de l'image fusionnée optique/radar.	133
Figure IV.14. Sous ensemble 2 (Ain Témouchent centre) de la carte d'occupation du sol à partir de l'image fusionnée optique et radar.	134
Figure IV.15. Sous ensemble 3 (région côtière d'Ain Témouchent) de la carte d'occupation du sol à partir de l'image fusionnée optique/radar.	134
Figure IV.16. Résultats d'optimisation des valeurs de paramètre Ntree de l'algorithme RF à partir de l'image fusionnée optique/radar pour les méthodes OBIA et pixel par pixel. .	136
Figure IV.17. Résultats d'optimisation des valeurs de paramètre Ntry de l'algorithme RF à partir de l'image fusionnée optique/radar pour les méthodes OBIA et pixel par pixel. .	137
Figure IV.18. Précisions par classe des classifications produites par les méthodes Pixel et OBIA.	137
Figure IV.19. Sous ensemble 1 (Ain Témouchent centre) de la carte d'occupation du sol à partir de l'image Pléaïdes.	143
Figure IV.20. Sous ensemble 2 (Ain Témouchent centre) de la carte d'occupation du sol à partir de l'image Pléaïdes.	144
Figure IV.21. Sous ensemble 3 (région côtière d'Ain Témouchent) de la carte d'occupation du sol à partir de l'image Pléaïdes.	144
Figure IV.22. Sous ensemble 1 (Ain Témouchent centre) de la carte d'occupation du sol à partir de l'image Sentinel-2.	145
Figure IV.23. Sous ensemble 2 (Ain Témouchent centre) de la carte d'occupation du sol à partir de l'image Sentinel-2.	146
Figure IV.24. Sous ensemble 3 (région côtière d'Ain Témouchent) de la carte d'occupation du sol à partir de l'image Sentinel-2.	146
Figure IV.25. Effet de la taille de l'échantillon patch de CNN sur OA.	148
Figure IV.26. Effet du paramètre d'échelle de segmentation sur OA.	150

Figure IV.27. Effets du paramètre Ntree sur l'OA de la classification. A : effets sur les données Sentinel-2. B : effets sur les données Pléiades.....	152
Figure IV. 28. Classification d'occupation du sol par la méthode CNN-OBIA. .	155
Figure IV. 29. Classification d'occupation du sol par le classificateur RF (OBIA)	155
Figure IV.30. Classification d'occupation du sol par le classificateur SVM (OBIA).....	156
Figure IV.31. Comparaison de la précision globale des résultats obtenus par les classificateurs RF, SVM et CNN.....	159
Figure IV. 32. Classification d'occupation par RF (image Landsat-5 TM, année 1999).....	162
Figure IV.33. Classification d'occupation par SVM (image Landsat-5 TM, année 1999)....	163
Figure IV.34. Classification d'occupation par RF (image Landsat-5 TM, année 2009).....	163
Figure IV.35. Classification d'occupation par SVM (image Landsat-5 TM, année 2009)....	164
Figure IV.36. Classification d'occupation par RF (image Sentinel-2, année 2020)	164
Figure IV.37. Classification d'occupation par SVM (image Sentinel-2, année 2020).	165
Figure IV.38. Superficie des classes d'occupation du sol par rapport à la superficie totale en (ha) en 1999, 2009 et 2020	168
Figure V.1. L'organigramme général de la méthode de simulation hydraulique appliquée dans l'étude.	181
Figure V.2. MNT et MNS utilisées dans la simulation hydraulique.....	185
Figure V.3. Représentation des termes d'équation énergétique.	188
Figure V.4. Géométrie créé sous HEC-RAS.....	191
Figure V.5. Résultats d'ajustement de la série hydrométrique de la station sidi Akkacha par les lois de distribution ; Gumbel, Log-normale, Log-normale III et Log-Pearson III.	195
Figure V.6. Comparaison graphique entre les lois d'ajustement.	197
Figure V.7. Débits maxima correspondants aux périodes de retour étudiées.	197
Figure V.8. Hydrogrammes de crue à la station hydrométrique de Sidi Akkacha pour les différentes périodes de retours : 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.....	198
Figure V.9. Profondeurs d'eau simulées par MNS tri-stéréo pour différentes périodes de retour: 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.....	200
Figure V.10. Vitesses d'écoulement simulées par MNS tri-stéréo pour différentes périodes de retour: 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.....	201
Figure V.11. Limites spatiales d'inondation simulées par MNS tri-stéréo pour différentes périodes de retour : 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.....	201
Figure V.12. Profondeurs d'eau simulées par MNT (12 m) pour différentes périodes de retour: 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.....	202
Figure V.13. Vitesses d'écoulement simulées par MNT (12 m) pour différentes périodes de retour: 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.....	202
Figure V.14. Limites spatiales d'inondation simulées par MNT (12 m) pour différentes périodes de retour: 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.	203
Figure V.15. Localisation des sections transversales.	205
Figure V.16. Ligne d'eau observée (crue 2017) et simulée (période de retour centennale) à la station transversale 150.....	206
Figure V.17. Ligne d'eau observée (crue 2017) et simulée (période de retour centennale) à la station transversale 350.....	207
Figure V.18. Ligne d'eau observée (crue 2017) et simulée (période de retour centennale) à la station transversale 750.....	208

Figure V.19. Cartes d'aléa inondation (MNS tri-stéréo) selon la classification (Smith et al., 2014)	209
Figure V. 20. Cartes d'aléa inondation reclassifiées (MNS tri-stéréo).	210
Figure V.21. Cartes d'aléa inondation (MNT 12m) selon la classification (Smith et al., 2014).	211
Figure V.22. Cartes d'aléa inondation reclassifiées (MNT 12 m).	211
Figure V.23. Classes d'occupation du sol inondées (MNS tri-stéréo).	212
Figure V. 24. Cartes de vulnérabilité au risque d'inondation (MNS tri-stéréo).....	213
Figure V. 25. Classes d'occupation du sol inondées (MNT 12 m).	217
Figure V. 26. Classes d'occupation du sol inondées (MNT 12 m).	217
Figure V. 27. Carte du risque global d'inondation (MNS tri-stéréo) pour les différentes périodes de retours étudiées.....	222
Figure V.28. Carte du risque global d'inondation (MNT 12 m) pour les différentes périodes de retours étudiées.	223
Figure V.29. Zoom sur le risque aléa simulé par la crue centennale (MNS tri-stéréo).....	225
Figure V.30. Zoom sur le risque global d'inondation simulé par la crue centennale (MNS tri- stéréo).....	226
Figure V.31. Indice d'élévation de bassin versant Oued Allala.	227
Figure V. 32. Indice de l'intensité des précipitations du bassin versant Oued Allala.	228
Figure V.33. Indice de densité de drainage.	229
Figure V. 34. Indice de pentes de bassin versant Oued Allala.	230
Figure V. 35. Indice d'occupation du sol (année- 2020).....	231
Figure V. 36. Indice d'occupation du sol (année- 2009).....	232
Figure V.37. Indice spatial de la caractérisation du risque d'inondation selon la méthodologie FIGUESD-S – Année 2020.....	233
Figure V. 38. Indice spatial de la caractérisation du risque d'inondation selon la méthodologie FIGUESD-S – Année 2009.....	234

LISTES DES TABLEAUX

Tableau II. 1. Classement des capteurs satellitaires selon la résolution spatiale.....	57
Tableau II. 2. Caractéristiques du Capteur radar Sentinel-1.	69
Tableau III.1. Inondations historiques dans la région Ain Témouchent.	90
Tableau III.2. Inondations historiques dans les région Chlef et Ténès	92
Tableau III. 3. Dates d’acquisitions et objectifs d’utilisation des images sentinel-2.	94
Tableau III.4. Caractéristiques spectrales des images Sentinel-2.	95
Tableau III.5. Dates d’acquisitions et objectifs d’utilisation des images sentinel-1.....	96
Tableau III. 6. Dates d’acquisition de objectifs d’utilisation des images Pléiades.	97
Tableau III.7. Caractérisqtiques spectrales et résolution spatiales des images Pléiades.	97
Tableau III.8. Métadonnées relatives à la géométrie d'acquisition (angle d'incidence et élévation solaire) des images Pléiades.....	98
Tableau III.9. Propriétés spectrales des bandes des images Landsat-5 TM.	99
Tableau III.10. Dates d’acquisition et objectifs d’utilisation des images Landsat-5 TM.	99
Tableau III.11. Paramètres morphométriques du bassin versant Oued Allala.	102
Tableau III.12. Surfaces partielles par tranche d’altitude.	103
Tableau III.13. Répartitions mensuelles des températures (ONM :1988-2009)	105
Tableau III.14. Vitesses moyenne du vent en m/s –Région de Chlef (ONM : 1988-2009)...	105
Tableau III.15. Caractéristiques de la station hydrométrique Sidi Akkacha.....	107
Tableau IV.1. Niveau 1 de sélection et de nomenclature des classes d'occupation du sol. ...	118
Tableau IV.2. Niveau 2 de sélection et de nomenclature des classes d'occupation du sol. ...	119
Tableau IV.3. Les valeurs des hyperparamètres dérivés pour le processus d'optimisation. ..	123
Tableau IV.4. Résultats Précision globale (OA) et coefficient kappa de RF et SVM appliqués pour les deux approches : pixel et OBIA.	133
Tableau IV.5. Résultats d’évaluation de la précision de la classification de l’occupation du sol à partir de l’imagerie Pléiades.....	140
Tableau IV.6. Résultats d’évaluation de la précision de la classification de l’occupation du sol à partir de l’image Sentinel-2.....	141
Tableau IV.7. Les précisions globales (OA) obtenues et kappa avec les images Pléiades et sentinel-2.....	142
Tableau IV.8. Résultats d’évaluation de la précision de la classification de l’occupation du sol à partir de l’image Sentinel-2.....	157
Tableau IV.9. Résultats d’évaluation de la précision de la classification	161
Tableau IV. 10. Superficies des classes d’occupation du sol.....	162
Tableau IV.11. Matrice de transition pour la période 1999-2009.....	166
Tableau IV.12. Matrice de transition pour la période 2009-2020	167
Tableau V.1. Fonctions de distribution de probabilité utilisées.	178

Tableau V.2. Courbes de risque combinées - seuils de vulnérabilité (d'après Smith et al, 2014).	193
Tableau V.3. Résultats de calcul de quantiles.	195
Tableau V.4. Résultats de calcul des critères AIC et BIC pour les différents modèles de distributions.....	197
Tableau V.5. Valeurs de coefficient de rugosité Manning en fonction de classes de l'occupation du sol.	199
Tableau V.6. Résultats de comparaison entre la ligne d'eau observée et la ligne d'eau simulée et de calcul de coefficient de détermination.....	199
Tableau V.7. Profondeurs d'eau simulées.....	204
Tableau V.8. Vitesses d'écoulements simulées.....	204
Tableau V.9. Zones inondées prédites (MNS tri-stéréo) pour les différents types d'occupation du sol dans la zone affectée par les inondations.	213
Tableau V. 10. Évaluation du risque à l'inondation en fonction de la superficie des différents catégories d'occupation du sol (MNS tri-stéréo).	215
Tableau V. 11. Zones inondées prédites (MNT 12 m) pour les différents types d'occupation du sol dans la zone affectée.....	218
Tableau V. 12. Évaluation du risque d'inondation en fonction des superficies des différents catégories d'occupation du sol (Smith et al, 2014) (MNT 12 m).	221
Tableau V. 13. Superficies des classes du risque global (MNS tri-stéréo).	222
Tableau V.14. Superficies des classes du risque globale (MNT 12 m).....	223
Tableau V.15. Répartition des surfaces à risque d'inondation selon les classes du risque global.	235

LISTE DES ACRONYMES

ADEOS	ADvanced Earth Observing Satellite
AIC	Information Criterion Akaike
ALOS	Advanced Earth Observation Satellite
ANRH	Agence Nationale des Ressources Hydriques
ANN	Artificial Neural Network
ASAR	Altitude Synthetic Aperture Radar
ASCE	American Society of Civil Engineers
ASTER	Advanced Spaceborne Thermal Emission and Reflection Radiometer
AVHRR	the Advanced Very High Resolution Radiometer
BIC	Bayesian information criterion
CART	Classification And Regression Trees
CDEM	Canadian Digital Elevation Model
CNES	centre national d'Etudes Spatiales
CNN	Convolutional Neural Network
DSM-OPT	Digital Surface Models from Optical stereoscopic very-high resolution imagery
ETM	Enhanced Thematic Mapper
ESA	Agence Spatiale Européenne
FAO	Food and Agriculture Organisation
FVI	Flood Vulnerability Index
GPS	Global Positioning System
GRD	Ground Range Detected
HEC-RAS	Hydrologic Engineering Centers River Analysis System
HRS	haute résolution spatiale
IA	Intelligence artificielle
IW	Interferometric Wide Swath
JERS-1	Japanese Earth Resources Satellite-1
LIDAR	Light Detection And Ranging
MERIS	the Medium Resolution Imaging Spectrometer pour GLOBCOVER
ML	Maximum Likelihood

MNS	Modèle Numérique du Surface
MNT	Modèle Numérique de Terrain
MODIS	the Moderate Resolution Imaging Spectroradiometer
MRE	Ministère des Ressources en Eau
NASA	National Aeronautics and Space Administration
NDBI	Normalized Difference Built-up Index
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
OA	Overall Accuracy
OBIA	Object Based Image Analyis
OLI	The Operational Land Imager
ONM	Office National de Météorologie
OTB	Orfeo ToolBox
PA	Producer's Accuracy
PALSAR	Phased Array type L-band Synthetic Aperture Radar
PPRI	Plans de Prévention de Risque d'Inondations
QGIS	Quantum Geographic Information System
RADAR	Radio Detection And Ranging
RBF	la fonction de base radiale gaussienne
RF	Random Forest
SAR	Synthetic Aperture Radar
SIG	Système d'Information Géographique
SNAP	Sentinel Application Platform
SPOT	Système probatoire d'observation de la Terre
SRTM	Shuttle Radar Topography Mission
SVM	Support Vector Machine
TM	Thematic Mapper
THRS	très haute résolution spatiale
UA	User's Accuracy
UAV	Unmanned Aerial Vehicle
UE	Union européenne
VH	Verticale-Horizontale
VV	Verticale-Verticale

TABLE DES MATIERES

INTRODUCTION GENERALE.....	19
CHAPITRE I : EVALUATION DU RISQUE D'INONDATION ET LA CONTRIBUTION DE LA TELEDETECTION POUR L'ETUDE DES ZONES INONDABLES	27
Introduction	27
I.1. Notions fondamentales du risque d'inondation.....	28
I.1.1. Définition, typologie et facteurs engendrant le phénomène d'inondation.....	28
I.1.2. Facteurs aggravant les inondations en Algérie	29
I.1.3. Risque d'inondation et ses composantes:	30
I.2. Approches de l'évaluation du risque d'inondation	31
I.2.1. Approches de l'évaluation de l'aléa inondation	32
I.2.2. Approches de l'évaluation de la vulnérabilité au risque d'inondation	37
I.2.3. L'évaluation du risque d'inondation	43
I.3. Apports de la télédétection pour l'étude des zones inondables et l'évaluation du risque d'inondation.....	43
I.3.1. Capteurs actifs pour la cartographie des zones inondables.	44
I.3.2. Capteurs passifs : pour la cartographie de l'occupation du sol.	46
I.3.3. Capteurs actifs et passifs pour la génération des modèles numériques de terrain ...	49
Conclusion.....	50
CHAPITRE II: ÉTUDE ET CLASSIFICATION DE L'OCCUPATION DU SOL DES ZONES INONDABLES PAR LA TELEDETECTION ET METHODES D'APPRENTISSAGE AUTOMATIQUE	54
Introduction	54
II.1. Télédétection et capteurs de télédétection pour la modélisation de l'occupation du sol	55
II.1.1. Définition de la télédétection	55
II.1.2. Classement des capteurs de télédétection.....	56
II.2. Etat de l'art sur l'utilisation des capteurs de télédétection pour la modélisation de l'occupation du sol.....	59
II.2.1. Télédétection optique	60
II.2.2. Télédétection Radar.....	67
II.2.3. Synergie optique et radar pour la modélisation de l'occupation du sol	70
II.3. Méthodes de Machine Learning pour la classification de l'occupation du sol.....	73
II.3.1. Méthode Pixel par pixel	74

II.3.2. Méthode Orientée Objet	75
II.3.3. Algorithmes de classification	76
II.4. Télédétection et évaluation des changements de l'occupation du sol.....	81
II.5. Évaluation de la précision de la classification de l'occupation du sol.....	83
Conclusion	84
CHAPITRE III : SITES D'ETUDE ET BASES DE DONNEES MISES EN ŒUVRE	88
Introduction	88
III.1. Sites d'études : villes côtières Ain Témouchent et Ténès	89
III.1.1. Site d'étude Ain Témouchent	89
III.1.2. Site d'étude Ténès.....	91
III.2. Données satellitaires	93
III.2.2. Image Sentinel-1	95
III.2.3. Images Pléaides.....	96
III.2.4. Image Landsat	98
III.2.5. Données topographiques	99
III.3. Présentation de bassin versant Oued Allala (Ténès) et données hydrométriques utilisées pour la modélisation hydraulique	101
III.3.1. Présentation générale et caractéristiques du bassin versant : Oued Allala	101
III.3.2. Caractéristiques morphométriques et topographiques	102
III.3.3. Courbe hypsométrique	103
III.3.4. Les caractéristiques climatiques.....	105
III.3.5. Caractéristiques géologiques.....	106
III.3.6. Données hydrométriques.....	106
Conclusion	107
Chapitre IV: Modélisation de l'occupation du sol des zones inondables par méthodes d'apprentissage automatique	109
Introduction	109
IV.1. Approche méthodologique pour la classification de l'occupation du sol : Application aux sites d'études : Ain Témouchent et Ténès	110
IV.1.1. Prétraitements des données satellitaires.....	110
IV.1.2. Calcul des indices spectraux et fusion des données optiques radar pour le site d'étude Ain Témouchent.....	112
IV.1.3. Fusion des images Sentinel-1 et Sentinel-2.....	116
IV.1.3. Définition des classes de l'occupation du sol	117
IV.1.4. Génération d'échantillons pour le processus d'entraînement et de validation de la classification.	120

IV.1.5. Méthodes de Machine Learning pour la classification	120
IV.1.6. Méthode CNN-OBIA.....	124
IV.1.7. Détection des changements de l'occupation du sol dans le bassin versant de l'Oued Allala.....	128
IV.1.8. Évaluation de la précision des classifications.....	130
IV.2. Résultats et discussion.....	131
IV.2.1. Synergie des données optiques et radar pour la cartographie de l'occupation du sol de la ville côtière Ain Témouchent par méthodes de Machine Learning	131
IV.2.2. Application des CNN combinés avec la méthode OBIA pour la cartographie de l'occupation du sol en zone côtière (Ain Témouchent).....	138
IV.2.3. Évaluation de la combinaison des (CNN) et la méthode OBIA pour la classification de l'occupation du sol à l'aide de l'imagerie satellitaire Sentinel-2 dans la région de Ténès	153
IV.2.4. Évaluation des changements de l'occupation du sol dans le bassin versant de l'Oued Allala par l'utilisation de la méthode OBIA et les algorithmes de machine Learning à l'aide de l'imagerie satellitaire Landsat-5 TM et Sentinel-2	159
Discussion générale et conclusion.....	169
CHAPITRE V : ÉVALUATION DU RISQUE D'INONDATION EN MILIEU URBAIN A PARTIR DES DONNEES SATELLITAIRES ET LA MODELISATION HYDRAULIQUE	175
Introduction	175
V.1. Analyse fréquentielle des crues et détermination des débits extrêmes.....	176
V.1.1 Tests d'homogénéité des séries.....	176
V.1.2. Modèles d'ajustement et détermination des débits extrêmes.....	178
V.1.3. Choix de la loi d'ajustement	178
V.1.3. Construction de l'hydrogramme des crues.....	179
V.2. Modélisation hydraulique	180
V.2.1. Classification de l'occupation du sol et assignement des valeurs de coefficient Manning de rugosité	181
V.2.2. Génération de modèle topographique	182
V.2.3. Description du modèle utilisée pour la simulation hydraulique.....	185
V.2.5. Evaluation du risque d'inondation.....	191
V.3. Résultats et discussions.....	194
V.3.2. Results de calcul de l'hydrogramme des crues pour les périodes de retour.....	198
V.3.3. Résultats de la simulation hydraulique et l'évaluation du risque d'inondation ...	198
V.4. Discussion générale	224
CONCLUSION GÉNÉRALE ET PERSPECTIVES	238
REFERENCES BIBLIOGRAPHIQUES	244

**INTRODUCTION
GENERALE**

INTRODUCTION GENERALE

Les inondations à travers le monde sont parmi les catastrophes naturelles les plus destructives, affectant les basses terres, les zones côtières et les villes urbanisées. Différentes études sur les risques naturels montrent la confrontation et la vulnérabilité des communes méditerranéennes aux inondations. Depuis l'année 1900, ces inondations ont provoqué au moins 85 milliards d'euros de dégâts dans les pays environnants la mer Méditerranée (Gaume et al., 2016). Dans ces zones et principalement en automne, l'arrivée des pluies intenses cause des inondations dévastatrices et soudaines (Ricard et al., 2012). Les facteurs anthropiques tels que l'augmentation des zones de peuplement, la croissance démographique et les activités économiques et agricoles, favorisent considérablement le risque d'inondation. Unanimement, il est accepté que ces inondations sont devenues un risque majeur à l'échelle mondiale.

En Algérie, de nombreuses catastrophes d'inondations ont été enregistrées pendant près d'un siècle. Ces inondations ont causé des dommages considérables et affectent principalement les zones urbaines, industrielles et agricoles.

Depuis une vingtaine d'années, les événements extrêmes d'inondations sont principalement provoqués par les débordements des cours d'eau. Cela a été le cas lors des événements douloureux de Bab El-Oued (Alger) en novembre 2001, de ceux enregistrés à Ghardaïa en 2008, d'Annaba en 2010 et aussi à Batna en 2011.

D'après, le rapport de 2020 établi par le Ministère des Ressources en Eau (MRE) sur la stratégie nationale de lutte contre les inondations, le territoire national Algérien, dénote plus de 865 zones confrontées au risque d'inondation, dont 87 sont déclarées à haut risque et 25 à risque extrême. Ces zones à risque représentent communément des territoires hydrologiques (plaines urbaines, cours d'eau et vallées) d'une grande importance socio-économique avec de multiples activités développées progressivement avec l'évolution démographique. Ainsi, ces zones inondables représentent désormais un imposant enjeu local et socio-économique.

Différents facteurs socio-économiques et environnementaux influencent la fréquence du risque d'inondation en Algérie. En effet, les inondations et leur récurrence sont potentiellement liées aux démarches d'aménagement et de planification du territoire. Cela nécessite donc une prise en compte temporelle et spatiale des différentes politiques pour une implémentation fiable des études d'aménagement et de gestion du risque d'inondation. Par ailleurs, l'occupation des zones inondables représente aujourd'hui une véritable problématique en Algérie, le fait que la

majorité des villes algériennes se sont construites autour de sources, le long des cours d'eau ou encore à leurs embouchures, notamment dans les régions côtières et malheureusement, plus la ville se développe en zone inondable, et plus elle est vulnérable au risque. Alors que, les problèmes relatifs aux méthodes d'aménagement intégrées à l'échelle du bassin versant, qui sont développées en tant que réponses face au risque d'inondation requièrent d'observations et des bases de données plus complexes nécessitent encore des efforts pour une meilleure quantification de la notion du risque.

Ce risque d'inondation est en conséquence défini comme une combinaison de deux aspects : « aléa et vulnérabilité ». Duquel l'aléa est uniquement le phénomène physique considéré, la crue, il dépend du comportement hydrologique du bassin versant et du fonctionnement hydraulique du réseau hydrographique.

L'aléa peut être quantifié grâce aux paramètres hydrologiques classiquement utilisés tels que la profondeur d'eau et la vitesse d'inondation associés à une période d'occurrence d'inondation. La vulnérabilité aux inondations se définit par les dommages économiques directs et indirects qui se produisent lorsque l'eau inonde une parcelle. L'importance de ces dommages est principalement assignable à une urbanisation et une occupation du sol mal projetées en plaine inondable, qui ont pour conséquence une augmentation de la vulnérabilité des habitats et des biens. La confrontation de ces enjeux socio-économiques et environnementaux aux inondations explique les efforts qui sont mis en œuvre pour analyser et comprendre ce phénomène afin de réduire le risque.

C'est pourquoi une volonté internationale s'est articulée autour du développement des stratégies de gestion du risque d'inondation depuis des décennies. L'objectif était systématiquement de réduire les pertes en vies humaines, les dommages matériels et les perturbations sociales et économiques causés par ces catastrophes naturelles. Les recherches se sont préalablement concentrées sur l'ampleur prévisible de l'aléa. De ce fait, des mesures structurelles ont été réalisées, basées principalement sur la construction d'ouvrages physiques comme les barrages, les digues et les canaux d'évacuation. L'objectif était de protéger les sociétés en réduisant la vulnérabilité par le contrôle de l'aléa. Par ailleurs, les mesures non structurelles ont pris en charge la prévision, la prévention, les systèmes d'alerte et l'aménagement du territoire et agissent considérablement sur la composante de la vulnérabilité. Dans ce cadre, des Plans de Prévention du Risque d'Inondation (PPRI) ont été mis en œuvre, sous une forme de mesures législatives et réglementaires. Ils permettent aux décideurs, autorités

locales et responsables d'aménagement du territoire, d'apporter une contribution significative de gestion, de planification et de contrôle de l'occupation du sol dans les zones à risque.

Pour la caractérisation de l'aléa, deux types de modélisations ont souvent été appliquées, la première concerne la modélisation hydrologique pour l'estimation des débits maximums annuels pour une période de récurrence précise et la seconde vise à estimer les niveaux d'eau correspondant aux débits maximums annuels déterminés. Ces modélisations impliquent la description de scénarios d'inondation, les données d'entrée telles que, les données pluviométriques (précipitations) et hydrométriques (débits), les informations topographiques et l'occupation et l'utilisation des sols dans la plaine inondable. La combinaison de ces deux modélisations produit en aval des caractéristiques spatiales et hydrauliques de l'aléa.

En revanche, la caractérisation de la vulnérabilité intervient quand les risques liés à l'aléa inondation deviennent plus fréquents quand la plaine affectée par ce risque est déjà sujette à une urbanisation non planifiée, une évolution rapide de l'occupation du sol et la non-planification du risque en lui-même. Ce contexte exige l'analyse de l'occupation du sol pour déterminer la sensibilité des enjeux socio-économiques (l'occupation du sol et la société) au phénomène, et quantifier les dommages provoqués par les inondations (Pottier et al. 2005).

Généralement, dans le contexte de l'étude des inondations en Algérie, les méthodes classiques développées pour l'étude et l'analyse du risque d'inondation concernant ces deux aspects, souffrent souvent de l'insuffisance de données et de l'absence d'observations sur de longues périodes pour une meilleure quantification du phénomène et la difficulté des relevés liés à la complexité d'accès aux terrains en zones inondables.

En ce sens, un recours aux nouveaux outils de technologie spatiale en matière de capteurs satellitaires et d'approches avancées de télédétection a été retenu pour faire face aux limites des méthodes de l'évaluation du risque d'inondation et les difficultés liées à l'acquisition des données réelles. La télédétection, avec la diversité de ses capteurs : actifs et passives ainsi que sa capacité stéréoscopique, ouvre des possibilités inédites pour l'identification, l'analyse des zones inondables, l'évaluation et la détermination du risque d'inondation ainsi qu'à la caractérisation des enjeux impactés lors d'un phénomène d'inondation.

Dans ce contexte, plusieurs satellites d'observation de la Terre ont été développés depuis le lancement de premier satellite en 1970 tels que des capteurs actifs comme ERS-1, ERS-2, Envisat-ASAR, RADARSAT, ALOS-PALSAR, TerraSAR-X, COSMO-SkyMed, SAR et

Sentinel-1 et passifs à savoir, Landsat, Sentinel-2, Spot et Pléiades. Chaque type de capteurs est associé à une mission précise dans le cadre de l'étude du risque d'inondation.

En effet, les capteurs actifs ou RADAR interfèrent principalement dans la caractérisation spatiale de l'étendue des limites des inondations grâce à leur capacité de revisite en période d'averse. Cependant, les capteurs passifs ou optiques permettent d'identifier finement les éléments sujets au risque tels que le cadre bâti, les grandes infrastructures et les surfaces agricoles. Ainsi, à travers les images satellitaires à haute (HRS) et très haute résolution spatiale (THRS), les caractéristiques naturelles de canal d'écoulement naturel et des surfaces de ruissellement peuvent être efficacement déterminées.

L'objectif cardinal assigné au travail de recherche de cette thèse est de pouvoir exploiter les données satellitaires pour l'étude et l'analyse du risque d'inondation des zones côtières inondables situées dans l'ouest Algérien et pouvant comporter un milieu urbain. Afin d'y parvenir à ce but, incontestablement des questions de recherche sont à formuler :

- Dans un contexte d'une analyse de l'aléa et de la vulnérabilité, quel est l'apport de la télédétection en tant qu'outil d'acquisition d'une information dynamique et réelle pour l'évaluation fiable du risque ?
- Quelles sont les données satellitaires à exploiter dans le cadre de l'étude des inondations ?
- Quelles sont les méthodes de traitement pour l'extraction de l'information de l'imagerie satellitaire ? Quelle est la méthode la plus adaptée pour l'étude fiable du risque.
- Peut-on combiner la modélisation hydraulique et la télédétection dans l'étude du risque à l'inondation ?
- Quels sont les avantages et les contributions et même les limites de cette approche intégrée ?

Pour répondre à ces questions et aux objectifs de thèse, le travail de recherche s'est articulé autour de deux orientations :

Première orientation : une zone inondable peut comprendre une urbanisation non planifiée, caractérisée par une évolution rapide de l'occupation du sol ce qui implique à scruter un solide moyen permettant de parvenir à évaluer la vulnérabilité. L'objectif est de mieux connaître l'ampleur du risque global d'inondation dans ces zones à travers la combinaison de différents aspects hydrauliques et socio-économiques pour la quantification des dommages causés par les risques d'inondation. Une modélisation précise de l'occupation du sol dans ces zones est donc

le meilleur moyen pour caractériser les enjeux spatiaux et aider à la planification la gestion et la mise en place des plans directeurs des zones inondables.

La télédétection et les techniques d'intelligence artificielles (IA), telles que les approches de Machine et Deep Learning, présentent des atouts incontournables pour la classification de l'occupation du sol et le cadre bâti. La modélisation de l'occupation du sol par les outils de télédétection est basée sur les données de l'imagerie satellitaire de haute et très haute résolution spatiale (THRS). Elle s'appuie sur des approches de classification fondées par les algorithmes de Machine Learning qui ont prouvé leur fiabilité dans la communauté de télédétection. Les approches de classification sont souvent fondées sur les deux notions « pixel » et « objet ». Dans la première notion, les pixels sont traités comme une entité indépendante en tenant compte seulement leurs caractéristiques spectrales. Par ailleurs, la deuxième combine des informations spatiales, spectrales et contextuelles pour regrouper les pixels en régions homogènes, puis les catégoriser en utilisant les algorithmes de classification.

Deuxième orientation : l'évaluation du risque d'inondation à partir d'une approche intégrant les résultats de la télédétection de classification de l'occupation du sol des zones inondables et la modélisation hydraulique tout en analysant les deux aspects :

- L'aléa : à travers une approche de modélisation hydraulique qui utilise des données hydrologiques et la probabilité d'occurrence et aussi les données topographiques à partir des modèles numériques de terrain et de surface acquis grâce à la télédétection.
- La vulnérabilité : à partir des informations précises de l'occupation des zones inondables et leur croisement avec des résultats de simulation de l'aléa et son étendue spatiale.

Pour répondre aux questions de recherche, la thèse est scindée en trois parties, qui se complètent, puis vient conclusion générale qui fait ressortir les principaux résultats et les perspectives éventuelles.

La première partie comprend un état de l'art des connaissances scientifiques qui vise à replacer la thèse dans son contexte thématique. Elle est organisée en deux chapitres.

Le premier chapitre aborde les notions principales concernant les inondations, les typologies et les facteurs augmentant le risque, les méthodes d'évaluation du risque d'inondation et enfin, la contribution des capteurs satellitaires optiques et RADAR pour l'étude des zones inondables.

En effet, l'évaluation du risque représente l'ensemble des approches et des techniques destinées à l'analyse quantitative et qualitative du risque en agissant sur ses deux composantes « aléa » et « vulnérabilité ». L'analyse de l'aléa à travers une modélisation hydraulique pour caractériser les inondations en termes de profondeur et d'étendue des eaux de crue ainsi que de la vitesse d'écoulement pour différents scénarios d'occurrence. Tandis que l'analyse de la vulnérabilité nécessite une combinaison des différents aspects du risque global d'inondation à travers la combinaison des attributs et des informations spatiales, hydrauliques et même socio-économiques pour la quantification des dommages causés par les inondations. La télédétection est donc utile dans les analyses des deux composantes.

Le second chapitre présente une synthèse des méthodes de traitement des images satellitaires et la classification de l'occupation du sol des zones inondables par les modèles d'apprentissage automatique (Machine Learning) et d'apprentissage profond (Deep Learning). Dans un premier temps, il met l'accent sur les divers capteurs de télédétection disponibles aujourd'hui en fonctionnement pour émettre le signal électromagnétique sur pratiquement tout le globe terrestre et leur grand potentiel pour étudier et analyser l'évolution spatio-temporelle de l'occupation du sol et la surveillance de l'environnement à travers des capteurs de télédétection. L'utilisation des méthodes de Machine Learning est devenue une méthode populaire intégrée dans la recherche en télédétection. Par conséquent, la modélisation de l'occupation du sol à l'aide de ces méthodes constitue une solution intéressante, à la fois en termes d'analyse de l'imagerie satellitaire aux différentes caractéristiques spectrales et spatiales de haute et très haute résolution spatiale, mais aussi pour extraire des informations utiles pour le contexte de l'étude des inondations un des objectifs de la thèse. La synthèse bibliographie confirme l'intérêt de tester ces méthodes et d'en évaluer les performances de classification d'images optiques à haute et très haute résolution. De même, en développant une approche synergique optique afin d'améliorer la précision de classification et obtenir plus d'informations spectrales et spatiales.

La deuxième partie comprend un troisième chapitre qui décrit les sites d'études et les données mises en œuvre. Les sites d'études sont présentés selon leurs caractéristiques hydrologiques et hydrauliques associées aux bases de données produites par l'exploitation des images satellitaires, ainsi que leur exposition au risque d'inondation.

La troisième partie s'articule autour de deux chapitres consacrés à l'application des approches méthodologiques de classification de l'occupation du sol et l'évaluation du risque d'inondation des zones inondables. En premier lieu, le chapitre IV est consacré à la modélisation de l'occupation du sol des zones inondables par les méthodes d'apprentissage automatique et

profond. Dans ce chapitre, différentes méthodes appliquées à différents types d'images satellitaires ont été testées. Le but est d'élaborer des cartes précises et utiles pour une caractérisation fiable des zones inondables et l'analyse du risque.

Le dernier chapitre s'intéresse à l'évaluation du risque d'inondation en milieu urbain menée à partir des données satellitaires et la modélisation hydraulique complète l'étude. Des simulations hydrauliques permettant de représenter l'extension d'ondes de crue dans les affluents. L'objectif de cette partie est de délimiter les plaines inondables et de simuler les niveaux d'eau en fonction de différents aspects spatiaux topographique et hydrologique.

En finalité, une conclusion générale ponctuera cette étude et permettra aussi de déceler les effets saillants obtenus à partir des résultats de pouvoir dégager des perspectives de recherches futures.

Partie I : ETAT DE L'ART

CHAPITRE I

ÉVALUATION DU RISQUE D'INONDATION ET LA CONTRIBUTION DES CAPTEURS SATELLITAIRES OPTIQUES ET RADAR POUR L'ETUDE DES ZONES INONDABLES

CHAPITRE I : EVALUATION DU RISQUE D'INONDATION ET LA CONTRIBUTION DE LA TELEDETECTION POUR L'ETUDE DES ZONES INONDABLES

Introduction

Dans le contexte de l'amélioration des méthodes de prévision et de gestion des inondations, des efforts scientifiques multidisciplinaires ont été consentis depuis plusieurs décennies en tenant compte toujours les problèmes d'incertitudes des observations et des difficultés d'accès aux terrains complexes. De nouvelles données et outils étaient nécessaires pour développer des systèmes précis de l'évaluation du risque et la prévision d'inondations, qui considèrent la variation spatio-temporelle des zones inondables, les conditions d'écoulement et le changement climatique perturbant les récurrences des inondations. C'est pourquoi, au cours des deux dernières décennies, un grand progrès de combinaisons des outils avancés de télédétection et de la modélisation hydraulique a été constaté. La télédétection offre non seulement une représentation spatiale de l'inondation, mais aussi, les données issues de ces outils peuvent être intégrées dans les modèles hydrauliques de simulation des inondations.

Ce chapitre vise à présenter une synthèse bibliographique des études liées au contexte de l'analyse et l'évaluation du risque d'inondation, la télédétection et la modélisation hydraulique au sein lesquelles notre travail est replacé. Il est organisé en trois sections principales. La première présente les notions fondamentales, facteurs et composantes du risque d'inondation, qui permettent de mieux comprendre le risque d'inondation dans les bassins versants et les efforts menés pour définir le concept général de ce risque. La deuxième section est consacrée à l'explication des approches de l'évaluation du risque d'inondation en fonction de ses composants aléas et vulnérabilité. Cette section explique les méthodes de l'évaluation de l'aléa inondation à travers les approches de la modélisation hydrologique et hydraulique afin de déterminer les caractéristiques hydrauliques d'un événement spécifique d'inondation. Les approches de l'analyse de la vulnérabilité y sont également décrites. Enfin, la troisième section décrit l'apport de la télédétection active et passive dans le contexte de l'étude des inondations.

I.1. Notions fondamentales du risque d'inondation

I.1.1. Définition, typologie et facteurs engendrant le phénomène d'inondation

D'après le Portail de la prévention des risques majeurs, ministère de l'Écologie et du développement durable (MEDD-PRIM), les inondations sont définies comme « un phénomène de submersion rapide ou lente, naturelle ou artificielle et temporaire d'une zone terrestre ». Globalement, selon le même dossier, « les inondations intègrent les débordements d'un cours d'eau, les remontées de nappes, les ruissellements des fortes pluies d'orages, les inondations par rupture d'ouvrages de protection, les inondations estuariennes résultant de la conjonction de fortes marées, de situations dépressionnaires et de la crue des fleuves ». D'après leurs causes, les inondations peuvent être d'origines naturelles ou anthropiques, ou souvent la combinaison des deux. En s'intéressant au contexte d'inondations en Algérie, d'après le dossier de la Stratégie Nationale de Prévention et de Gestion des Risque d'Inondation (2020), différents types d'inondation peuvent être engendrés :

- **Crue lente, graduelle** : en général, ce type d'inondation caractérise les grands bassins, ou les équipements d'évacuation des crues fortes sont insuffisants (réseaux d'assainissement et de drainage.... etc.). Le temps de la montée de la crue est supérieur à 12 heures pour avec un volume écoulé très grand, la crue peut durer 2 à 3 jours.
- **Crue rapide** : elle se produit dans des bassins versants moyens (des centaines à des milliers de kilomètres carrés de superficie), des affluents des grands Oueds et des Oueds côtiers (leur embouchure à la mer). Le temps de montée des crues rapides est compris entre 2 et 12 heures et la crue peut durer au maximum 24 h.
- **Crue éclair** : elle est causée par de fortes précipitations sur de petits bassins versants (capables de couvrir une surface d'une centaine de kilomètres carrés), généralement très escarpés. Le temps de montée est très court (< 2 heures).
- **Ruissellement pluvial urbain** : pluies directes dans les zones urbaines étanches et/ou ruissellement rapide des eaux débordant de petits ruisseaux à la périphérie de la ville.
- **Remontée de la nappe phréatique** : elle se produit par la remontée d'une nappe phréatique déjà remplie sous des fortes précipitations. Cela peut entraîner que le niveau de la nappe atteigne la surface du sol et l'inonde.
- **Crue avec transport solide significatif** : il caractérise les bassins versants à pentes fortes et des massifs très dégradés. Ce type de crue est souvent combiné à d'autres typologies, par exemple, les crues lentes, rapides ou éclairs.

- **Submersion marine** : généralement les phénomènes marins tels que houles, marées d’ampleurs inhabituelles, ondes de tempête, raz-de- marée peuvent causer une élévation du niveau marin. Un débordement sur la terre de la mer peut être engendré suite à cette élévation.

En Algérie, à travers l'analyse de la morphologie hydrologique du pays, du climat, des caractéristiques hydrologiques, les types d'inondations subies par le territoire national (qu'elles soient d'origine naturelle ou non) a été déterminé par les autorités responsables de la gestion de ce risque. Plus de 48 % des inondations sont causées par les ruissellements urbains, les crues rapides représentent 21 %, les crues lentes respectivement avec 12 % et 11 %. Les remontées de nappes phréatiques et la submersion marine sont moins rencontrées (figure I.1).

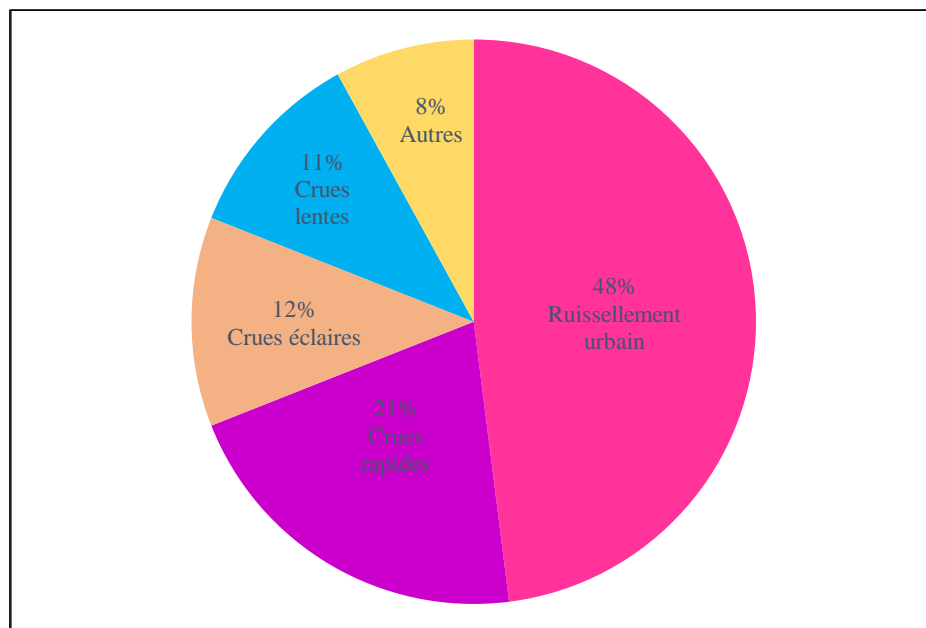


Figure I. 1. Différents types d’inondation en Algérie.

I.1.2. Facteurs aggravant les inondations en Algérie

Les inondations en Algérie sont principalement dues :

- A l’insuffisance de la perception du risque d’inondation. Il s'agit de la compréhension personnelle du risque d'un individu et est généralement considéré dans la littérature comme une combinaison de la probabilité perçue de subir un danger et de ses conséquences potentielles perçues. En d'autres termes, cette perception est un processus complexe et est influencée par une gamme de facteurs cognitifs, socio-économiques et géographiques qui peuvent mobiliser les sens comme la fonction neuronale. Il représente essentiellement le comportement, les déclarations, les croyances, les

stratégies d'adaptation et la réactivité collective ou individuelle d'un individu face aux risques qui surviennent (Verlynde, 2018).

- Aux problèmes relatifs à la planification et l'aménagement du territoire : ici, les risques d'inondation et leur récurrence sont fortement liés aux démarches d'aménagement du territoire qui n'appréhendent pas bien les enjeux liés à la gestion de l'eau, dans les stratégies d'aménagement du territoire.
- A l'occupation des zones inondables : véritable problématique, ses conséquences aggravent de plus en plus les inondations. En effet, La majorité des villes algériennes se sont construites autour de sources, le long des cours d'eau ou encore à leurs embouchures, notamment dans les régions côtières, et malheureusement, plus la ville se développe en zone inondable, et plus elle est vulnérable à ce risque.
- Au manque d'instruments pour la gestion de crise et de la prévision du risque ainsi qu'la réalisation d'aménagement sans étude préalable précise sont également des facteurs qui peuvent augmenter les inondations.

I.1.3. Risque d'inondation et ses composantes:

Le risque d'inondation se définit par:

- L'aléa, un phénomène physique, qui est caractérisé par son extension spatiale, sa fréquence, sa durée et sa saisonnalité.
- La vulnérabilité, un fait socio-économique et politique, caractérisée par sa gestion et sa perception et par son coût psychologique et économique.

L'aléa : est un phénomène physique, naturel et non maîtrisable, défini par son occurrence et son intensité aléatoire (pluies, typhon, inondation...) (MEDD, 2004a ; MEEDDAT, 2008; Lacina, 2012). Cet aspect naturel et physique de l'inondation est défini par des caractéristiques hydrauliques qui qualifient l'aléa, tel que, la période de retour de crues, la hauteur et la durée de crue, la vitesse d'écoulement et le volume de matière transportée (Tacnet et Burnet, 2007). Par ailleurs, la probabilité d'apparition, autrement dit la période de retour est un paramètre déterminant de l'aléa inondation.

La vulnérabilité : l'aléa en lui-même ne constitue pas un risque social. La présence d'installations humaines (bâtiments d'habitation) dans la plaine inondable peut être affectée par des aléas (tempêtes) entraînant des situations à risque (inondation des constructions par le débordement de cours d'eau). Si le risque devient catastrophique, les conséquences peuvent être amplifiées par des facteurs de vulnérabilité (bâtiments inondés) (Creach,

2016). Autrement dit, selon (Reghezza, 2007), si la probabilité d'occurrence du phénomène physique extrême est constante, alors la seule explication logique de l'augmentation des catastrophes doit être dans la vulnérabilité croissante des populations aux phénomènes physiques extrêmes.

Dans la littérature, de très nombreuses définitions de la vulnérabilité peuvent être trouvées :

« La vulnérabilité apparaît comme la propension d'une société donnée à subir des dommages en cas de manifestation d'un phénomène naturel ou anthropique. Cette propension varie selon le poids de certains facteurs qu'il est nécessaire d'identifier et d'analyser car ils induisent un certain type de réponse de la société » (D'Ercole et al. 1994).

A l'échelle internationale, il a été souligné dans nombreuses manifestations scientifiques que les risques naturels sont une conséquence d'une interaction de la nature et de la société et que seule la gestion rationnelle, raisonnable et raisonnée de notre environnement est à même de réduire les catastrophes naturelles. Conformément à l'approche technocentriste apparue dans les années 1970, le risque est défini comme une probabilité de pertes ou de dommages pour un élément donné soumis à un événement naturel.

Le risque est la combinaison d'occurrence d'un événement spécifique (aléa) et de l'impact que cet événement causerait en cas d'occurrence (vulnérabilité). Donc, il peut s'exprimer par la relation suivante :

$$\text{Risque} = \text{Probabilité} \times \text{Vulnérabilité} \quad (\text{II.1})$$

Où la probabilité est liée à l'occurrence d'un processus physique qui est l'aléa inondation et la vulnérabilité désigne en fait la valeur des enjeux. Cette relation estime donc quantitativement le potentiel d'endommagement d'un élément donné (personnes, infrastructures...etc.). L'analyse quantitative du potentiel d'endommagement est en général faite sous forme d'indice d'exposition, nombre de personnes ou la valeur des biens qui se trouvent dans la zone de l'étendue spatiale de l'aléa (Sayers et alii, 2002 ; Reghezza, 2007).

I.2. Approches de l'évaluation du risque d'inondation

L'évaluation des risques d'inondation est l'ensemble des techniques destiné à l'analyse quantitative des risques d'inondation, en agissant sur ses deux composantes, leurs différentes variables et paramètres. Les techniques modernes d'analyse et d'évaluation du risque d'inondation sont fondées sur une combinaison de l'aléa inondation, de la probabilité d'occurrence et ses conséquences négatives des inondations sur la santé humaine, les activités

économiques, l'environnement et le patrimoine culturel (Solin et Skubincan, 2013). Dans la littérature, plusieurs travaux scientifiques portent sur l'étude du risque d'inondation selon différentes approches : études sur l'évaluation de l'aléa inondation, cartographie spatiale, analyse et évaluation de la vulnérabilité et évaluation socio-économiques des dommages causés par les inondations.

I.2.1. Approches de l'évaluation de l'aléa inondation

L'évaluation de l'aléa inondation est une tâche complexe qui nécessite un large éventail de données réelles et spatiales. Les approches classiques et modernes de l'évaluation de l'aléa inondation exploitent les données de relevés de terrain, les observations réelles au niveau des stations hydrologiques et les données provenant de la télédétection spatiale.

Dans l'analyse de l'aléa, deux étapes principales sont considérées : l'estimation des débits maximums annuels pour différentes probabilités de dépassement et l'estimation des niveaux d'eau pour les débits maximums annuels déterminés. En d'autres termes, la première étape est la réalisation d'une modélisation hydrologique et la seconde implique une modélisation hydraulique.

Ces modélisations requièrent la description de scénarios d'inondation, les données d'entrée telles que, les données pluviométriques (précipitations) et hydrométriques (débits), les informations topographiques et l'occupation et l'utilisation des sols dans la plaine inondable. La combinaison des deux sortes de modélisation produit en aval des caractéristiques spatiales et hydrauliques déterminant l'aléa telles que, la profondeur d'eau et la vitesse d'écoulement et l'étendue des inondations selon le scénario étudié.

I.2.1.1. Analyse et modélisation hydrologique

Les modèles hydrologiques sont généralement conçus pour la prévention des différents processus hydrologiques. Ils sont développés essentiellement pour examiner l'interaction entre l'eau, l'occupation du sol, le sol et le changement climatique. Dans la construction de tels modèles, deux paramètres essentiels sont pris en compte : la pluie et le débit. Dans les terrains complexes, la topographie, la géologie et les nappes aquifères dont également des paramètres nécessaires à prendre en compte (Abdulkareem et al., 2018). Dans ce sens, plusieurs méthodes sont entreprises pour l'estimation des débits maximums à travers la modélisation hydrologique. De manière générale, elles sont divisées en deux catégories de base : la première est constituée de modèles pluie-débit et la seconde est basée sur les approches statistiques de la détermination des débits maximums.

Le choix d'un modèle dépend du type de bassin versant et de l'objectif de la prédiction hydrologique dans ce bassin. Cela permet une représentation simplifiée d'un système réel de bassin versant pour obtenir une meilleure compréhension des processus hydrologiques dans une région étudiée. En conséquence, plusieurs modèles ont été créés pour simuler le comportement hydrologique d'un bassin versant. Ces modèles sont classés comme déterministes ou stochastiques, empiriques, conceptuels ou physiques (Devia et *al.*, 2015).

En ce qui concerne les modèles pluies-débit, le choix d'un modèle approprié dépend du niveau spatial auquel le débit de crue est estimé. Il existe plusieurs formules empiriques avec peu de paramètres (par exemple, formules rationnelles, et régionales) (Widasmara et *al.*, 2019), où des équations de régression sont applicables aux grandes échelles.

Typiquement, dans les formules empiriques, la valeur du débit maximal annuel est fonction de la superficie du bassin versant et des propriétés physico-géographiques du bassin versant. Néanmoins, pour les petites échelles (locales par exemple), des méthodes plus sophistiquées de transfert des pluies en débits sont applicables, telles que la méthode de l'hydrogramme unitaire ou les modèles déterministes à paramètres spatialement distribués ou forfaitaires (Beven, 1985 et 2000 ; Blackie et Eeles, 1985). Globalement, les modèles pluies-débit simulent les valeurs de débit pour l'intervalle de temps de l'ensemble de l'onde de crue.

Les approches statistiques sont basées sur la théorie des probabilités. La détermination des probabilités des débits maximums annuels se fait en matière de la fonction de distribution. Cette fonction est définie par des paramètres de position, de variabilité, d'asymétrie et de la courbure de la distribution de probabilité. Le calcul de ces paramètres repose sur des statistiques hydrologiques comme la méthode des moments (traditionnelle, linéaires ou pondérées) ou la méthode de maximum de vraisemblance (Tartakovsky, 2013).

Toutefois, ces méthodes statistiques de détermination des débits maximums sont limitées par la nécessité de longues observations à partir des stations jaugées.

I.2.1.2. Analyse et modélisation hydraulique

La gestion appropriée des inondations nécessite une amélioration de la compréhension de l'aléa, l'objectif principal de la modélisation hydraulique. En règle générale, la modélisation des inondations implique le développement d'algorithmes utiles pour caractériser les inondations en termes de profondeur et d'étendue des eaux de crue ainsi que de vitesse d'écoulement (Bates et *al.*, 2005). En effet, les résultats de la modélisation hydraulique sont un appui pour la gestion des risques d'inondations. Les écoulements d'eaux des crues sont conceptualisés sous forme de phénomènes ondulatoires propageant dans une direction descendante et soumis à des variations

dans le débit, le niveau d'eau et la vitesse. C'est pourquoi, les modèles hydrauliques simulent la propagation des eaux de crue d'un point à un autre dans un intervalle spatial à travers la résolution des équations numériques (Nkwunonwo et al., 2020; Ozdemir et al., 2013; Chow, 1988). Conformément aux modèles hydrologiques, les modèles hydrauliques requièrent des vérités terrain et des observations historiques des crues pour le calage et la validation de modèle (Ballesteros et al., 2011). Cela assure la représentation fiable de l'aléa et en conséquence, une gestion fiable suivant une approche intégrée du risque d'inondation.

Dans la modélisation hydraulique, deux méthodes d'estimation des niveaux d'eau des débits de crues, existent : une estimation des niveaux d'eau en temps réel pour des intervalles fixés du temps sur toute la durée de la crue et une estimation des niveaux d'eau pour un débit maximum précis de crue à une probabilité spécifiée qui ne tient pas toute l'étendue d'une onde de crue en son temps réel.

Concernant les modèles de simulation hydraulique, ils sont généralement basés sur l'application de modèles unidimensionnels (1D) ou bidimensionnels (2D) d'écoulements stables ou transitoires construits par les équations de Saint-Venant (Wang et al., 2003). Dans les modèles d'inondation 1D, tels que HEC-RAS 1D, SOBEK 1D et MIKE 11 ou ISIS la géométrie de terrain est représentée comme une séquence de sections transversales de la rivière et de la plaine d'inondation perpendiculaires à la direction de l'écoulement (Brunner, 2016). Généralement, les modèles 1D nécessitent peu de données d'entrée et sont très adaptés aux cours d'eau et rivières à une géométrie simple. Ils permettent d'estimer l'impact des structures hydrauliques sur l'écoulement. En outre, les terrains à lit mineur complexe sont également bien représentés avec le 1D (Figure I.2). Cependant, ces modèles considèrent que l'eau reste à l'intérieur de la plaine d'inondation et ne tiennent pas compte des écoulements latéraux. Ces modèles peuvent produire des représentations moins précises des écoulements de surface, notamment dans la zone urbaine à grandes échelles.




Figure I.2. Visualisation d'une géométrie construite par un modèle 1D (Pons et al., 2014).

Néanmoins, les modèles hydrodynamiques 2D considèrent une variation de l'écoulement dans les deux directions longitudinale et transversale du canal de la rivière (Tarekgn et al. 2010). Ils s'adaptent parfaitement aux grandes échelles spatiales. Ils permettent de modéliser les écoulements en surface avec une représentation plus fiable du lit majeur. Tous les obstacles d'écoulement sont pris en compte notamment en zone urbaine, ce qui permet d'envisager une étude précise des écoulements dans les milieux urbains.

Mais ce modèle nécessite du temps et une grande quantité de données et contribue à une mauvaise intégration des structures complexes (ponts, buses et autres structures ponctuelles). Les modèles d'inondation 2D fréquemment appliqués comprennent les modèles SOBEK, FLS, LISFLOOD-FP, Telemac 2D, Flo2D Pro, RRI, Flow-2D, HEC-RAS 2D et MIKE Flood (Yin et al. 2020). Une visualisation d'un modèle 2D est présentée dans la figure I.3.




Figure I.3. Visualisation d'un modèle 2D (Marant, 2009).

Les modèles 1D et 2D peuvent être intégrés en un seul modèle pour former le modèle couplé 1D/2D. Ce modèle propose d'utiliser un modèle 1D pour représenter le lit mineur et un modèle 2D pour représenter le lit majeur (figure I.4).

L'objectif principal du modèle 1D/2D est de modéliser les écoulements de surface qui peuvent devenir complexes et le couplage des deux approches 1D et 2D permet, d'une part, de bien représenter les écoulements du lit mineur et ses ouvrages à travers le 1D et, aussi mieux représenter les débordements sur la surface et l'impact de bâti et l'occupation du sol sur les écoulements (par l'intégration de 2D).




Figure I.4. Visualisation d'un couplage 1D/2D (Marant, 2009)

Le choix d'un modèle dépend de la quantité et la qualité des données d'entrée, des variables hydrauliques à estimer, de la complexité hydraulique du site d'étude et ainsi la présence ou non de structures complexes (ponts, seuils, buses...) dans le cours d'eau à modéliser.

Par ailleurs, la construction d'un modèle hydraulique implique une représentation précise de la topographie de la plaine inondable y compris la géométrie des sections transversales, la pente du terrain, des limites du chenal principal d'écoulements et du lit majeur. Ces données sont indispensables pour élaborer un modèle hydraulique, elles sont généralement disponibles sous forme de données de levé topographique de terrain ou sous forme de modèles numériques de terrain (élévation et surface) générés à partir d'outils de télédétection. La représentation des cours d'eau dans les modèles numériques de terrain est cruciale pour la fiabilité des modèles d'inondation. Pour les données topographiques de type élévation ou surface, la résolution

spatiale est un facteur clé pour leur précision. Ainsi, la fiabilité des modèles d'inondation est fortement liée à la résolution et à la précision des données topographiques utilisées (Saksena and Merwade, 2015).

La mise en fonction d'un modèle hydraulique nécessite également la définition des conditions aux limites d'écoulements en amont et en aval du cours d'eau étudié. Globalement, la condition amont correspond à l'insertion des débits de pointe des périodes de retour étudiées ou des hydrogrammes des crues, issus du modèle hydrologique. Cependant, la condition limite aval correspond à la hauteur normale d'écoulements calculée par le modèle à travers la formule de Manning Strickler. En effet, cette condition représente la hauteur d'eau théorique que prendrait le cours d'eau pour les conditions hydrauliques et géométriques d'une section donnée si le régime était uniforme. L'écoulement uniforme est considéré comme un régime théorique que l'écoulement tendrait à adopter s'il n'était contraint à la variation par la géométrie du lit.

La formule de Manning Strickler est exprimée comme suit :

$$Q = KSR^{\frac{2}{3}}I^{0.5} \quad (\text{II.2})$$

Où :

K : Coefficient de Strickler ; S : Surface mouillée de la section ; R : Rayon mouillé de la section;
I : Pente du lit du cours d'eau.

Par ailleurs, la validation d'un modèle hydraulique passe par le calage qui se fait en fonction du paramètre de rugosité et des données théoriques disponibles notamment sur les crues historiques.

D'une manière générale, le calage consiste à faire varier les coefficients de Strickler, décrivant la rugosité qui caractérise la zone inondable (lit mineur, lit majeur et surfaces d'écoulements) autour des valeurs correspondantes jusqu'à retrouver, par le calcul, les cotes observées pour des crues, appelées crues de calage.

I.2.2. Approches de l'évaluation de la vulnérabilité au risque d'inondation

Les risques liés à l'aléa inondation deviennent plus fréquents quand la plaine affectée par ce risque est déjà sujette à une urbanisation non planifiée, une évolution rapide de l'occupation du sol et la non-planification du risque en lui-même. Ce sont ces facteurs qui peuvent contribuer à des effets plus graves des inondations touchant notamment la vie humaine des habitants. C'est

pourquoi, l'analyse de la vulnérabilité au risque d'inondation est un volet très important qui implique une attention afin de mieux comprendre l'ampleur du risque global d'inondation.

Selon la littérature récente relative à l'évaluation du risque d'inondation, différentes approches ont été proposées pour l'évaluation et l'analyse de la vulnérabilité au risque d'inondation. Le choix et l'élaboration d'une approche sont toujours en fonction de la disponibilité des données nécessaires et la nature de terrain inondable (Par exemple : rural ou urbain). En général, deux approches sont fréquemment abordées dans plusieurs études.

La première approche propose une évaluation de la vulnérabilité en fonction de la propension aux dommages causés par les inondations, la résistance aux inondations et la capacité de récupération uniquement en termes de propriétés des systèmes sociaux, économiques et environnementaux. Par exemple, les maisons en terre sont généralement considérées comme plus susceptibles d'être endommagées par les inondations que les maisons en briques.

On s'attend également à des dommages plus importants dans le cas des maisons à un seul étage que dans celui des maisons à plusieurs étages. De même, les personnes âgées et moins agiles ont plus de mal à échapper aux effets des inondations que les jeunes, etc.

Les personnes aisées disposant d'une épargne et celles qui sont assurées contre les dommages causés par les inondations, ou encore les personnes disposant d'un capital social, sont plus à même de faire face aux effets négatifs des inondations que les personnes pauvres, non assurées, etc. Cette approche est appelée l'évaluation de la vulnérabilité indépendamment de l'aléa (Adger et al. 2004). Autrement dit, l'indépendance de l'aléa, c'est un concept de l'évaluation de la vulnérabilité qui ne tient pas compte les caractéristiques hydrauliques et spatiales de l'aléa inondation sur la vulnérabilité, et bien, ce sont d'autres facteurs qui influencent la composante vulnérabilité. Et donc, les principaux éléments de détermination de la vulnérabilité sont les unités spatiales qui peuvent être à la fois des lieux ou des unités délimitées selon plusieurs critères.

Les travaux menés dans ce contexte ont souligné que la vulnérabilité est déterminée en fonction de différentes caractéristiques sociales, économiques et environnementales. Ces caractéristiques visent à quantifier la sensibilité d'une unité spatiale soumise au danger et influencent la capacité à s'en remettre.

Dans la littérature, il existe nombreuses approches méthodologiques de quantification de la vulnérabilité indépendamment de l'aléa inondation. Étant donné qu'il n'est pas possible de l'évaluer, elle peut être exprimée à travers des variables ou des indicateurs économiques.

En effet, la méthode basée sur les indicateurs de vulnérabilité est très présente dans les études de l'évaluation de la vulnérabilité au risque d'inondation. Elle est souvent adoptée selon les données disponibles, et permet d'élaborer une carte de vulnérabilité d'une entité spatiale. Ce type d'approche est souvent recommandé par les décideurs de planification et de gestion des zones inondables. La sélection des indicateurs de vulnérabilité est souvent liée au niveau de précision spatiale souhaité. Généralement, selon (Fekete et al. 2010), le détail et la précision spatiale des informations sur la vulnérabilité diminuent avec l'augmentation des dimensions spatiales du niveau local, régional et national. Les sources de données pour les études de vulnérabilité aux niveaux national et régional sont les recensements de la population, les statistiques nationales et les cartes d'occupation du sol.

Les données d'évaluation de la vulnérabilité au niveau local proviennent d'enquêtes et d'études approfondies de terrain. La combinaison de toutes les données collectées sous forme d'indicateurs fournit la quantification des dommages et des pertes potentielles pour les systèmes économiques, l'impact potentiel des dommages sur les systèmes sociaux, l'inconfort et le stress, et la quantification des changements de la qualité à systèmes environnementaux. D'autres mesures de résistance et de résilience peuvent exprimer la capacité d'un système particulier à réagir et à se remettre des inondations.

Cependant, ces méthodes sont confrontées à une énorme complexité en raison de nombreux problèmes liés à la normalisation, à la pondération et à l'agrégation des indicateurs ainsi qu'une difficulté de quantification de certains indicateurs.

Selon de nombreuses études, la combinaison de différentes variables économiques, sociales et environnementales, différents indices et aspects de l'évaluation de vulnérabilité ont été établis.

Par exemple, (Hoque et al., 2019) ont évalué la vulnérabilité aux inondations à Kalapara Upazila au Bangladesh suivant un processus multicritères d'analyse hiérarchique. L'approche développée intègre une dizaine de critères regroupés sous trois groupes : vulnérabilité physique, vulnérabilité sociale et capacité d'adaptation. Les critères ont été convertis en couches spatiales, pondérés et standardisés pour soutenir le processus d'analyse hiérarchique.

Des cartes de composantes de vulnérabilité individuelles ont été créées en utilisant une technique de superposition pondérée, puis des cartes de vulnérabilité finales ont été produites à partir de celles-ci. Les étendues spatiales et les niveaux de vulnérabilité ont été identifiés avec succès à partir des cartes produites.

De même, (Solín et *al.*, 2018) à travers des questionnaires et enquêtes de terrain ont associé des variables de substitutions à l'exposition et la susceptibilité des biens et des infrastructures aux dommages causés par les inondations. L'évaluation de la vulnérabilité par ces variables est basée sur des critères et des indices représentant les aspects individuels et globaux de la vulnérabilité.

Des indices, de susceptibilité des biens aux dommages (ISPD), de susceptibilité aux dommages physiques et mentaux (ISPMH) et de résilience aux inondations (IFR) ont été élaborés et la combinaison de ces indices conduit à la formulation de l'indice de la vulnérabilité globale des communes (IOVC). Cette évaluation a permis de proposer des mesures individuelles et institutionnelles spécifiques pour chaque communauté afin de réduire la vulnérabilité des habitations aux risques d'inondation.

Par ailleurs, (Balica et Wright, 2010) ont proposé une méthodologie pour améliorer l'indice de vulnérabilité aux inondation (FVI). Cet indice est très utilisé dans les études de l'évaluation du risque d'inondation, et comprend plusieurs indicateurs. Certains indicateurs n'ont aucune influence sur les résultats, par conséquent cette étude a présenté une analyse effectuées pour sélectionner les indicateurs les plus pertinents pour élaborer un faible indice FVI.

En revanche, conformément à (Coburn et *al.*, 1994) qui a défini la vulnérabilité comme « le degré de perte pour un élément ou plusieurs d'éléments à risque donné résultant d'un aléa donné à un niveau de gravité donné », la deuxième approche évalue la vulnérabilité par rapport aux attributs particuliers de l'événement d'inondation, y compris l'étendue spatiale de l'inondation, la hauteur du niveau d'eau et la vitesse d'écoulement.

Selon cette approche, la vulnérabilité est donc dépendante de l'aléa. Le concept de cette méthode signifie que le sens de la vulnérabilité est un peu déplacé du contexte économique, social et environnemental, et plutôt correspond ou est en relation avec le contexte aléa inondation.

Par exemple, l'approche mentionnée dans la figure (figure I.5), proposée par (Solín et Skubincan, 2013). Cette approche a été très développées dans les recherches. Elle consiste à

évaluer les dommages causés par les inondations aux biens, aux infrastructures et aux activités économiques en suivant quatre étapes principales :

- 1) Probabilité d'occurrence en fonction du débit maximum annuels.
- 2) les niveaux d'eau en fonction en fonction du débit maximum annuels.
- 3) Les niveaux d'eau en fonction des dommages causés par les inondations.
- 4) Dommages causés par les inondations en fonction de la probabilité.




Figure I. 5. Illustration de la méthode de calcul de la vulnérabilité en fonction des aléas (Solin et Skubincan, 2013).

De cette façon, cette approche nécessite une modélisation hydraulique des inondations au moyen des modèles hydrauliques, ensuite, les fonctions de dommages indiquant le degré de dommages aux biens sont exprimées par les niveaux d'eau et parfois par la vitesse d'écoulement de l'eau.

(Balica et *al.*, 2013) ont comparé les deux approches : l'approche de l'analyse des inondations par le biais des modèles hydrodynamiques et l'approche paramétrique de l'évaluation de la vulnérabilité. La première approche consiste à construire un modèle de simulation hydraulique pour identifier les zones inondables puis calculer les dommages associés à l'inondation en utilisant plusieurs critères y compris la densité de population, les surfaces de cultures, le nombre de maisons dans la zone inondée et le nombre moyen de familles par maison inondée. La

deuxième approche a consisté à calculer l'indice FVI (*Flood Vulnerability Index*) par le biais de trois indicateurs, principalement l'exposition, la sensibilité et la résilience. La comparaison effectuée lors de cette étude a montré que l'approche paramétrique basée sur la détermination de l'indice FVI est plus adaptée à l'évaluation de la vulnérabilité tandis que l'approche déterministe, bien qu'elle ait une évaluation limitée de la vulnérabilité, dispose d'une meilleure base scientifique.

Par exemple, (Creach, 2015) a combiné les hauteurs d'eau potentielles à l'intérieur des bâtiments, la proximité aux digues, le type architectural et la distance aux zones refuges pour identifier les zones vulnérables à travers un indice de Vulnérabilité Intrinsèque Extrême (V.I.E). L'indice a permis de quantifier la vulnérabilité de certaines communes du littoral atlantique français et a confirmé l'exposition des territoires impactés en 2010.

(Mahato et al. 2021) ont appliqué des modèles de susceptibilité aux inondations basés sur des réseaux neuronaux artificiels (ANN), des fonctions à base radiale (RBF) et des forêts aléatoires (RF). Les modèles de sensibilité aux inondations ont été construits suivant neuf indicateurs d'inondations. Ces modèles ont été également validés par un modèle hydrodynamique, puis un indice de vulnérabilité aux inondations (FVI) a été établi pour la comparaison. Les résultats obtenus dans cette étude ont montré que les performances des modèles de sensibilité aux inondations sont supérieures à celles d'autres modèles basés sur l'apprentissage automatique et que les modèles de simulation d'inondation et FVI ont également été ajustés spatialement avec les modèles de susceptibilité aux inondations.

(Zhang et al. 2022) ont combiné les deux modèles hydrologique et hydraulique unidimensionnel pour la cartographie et l'évaluation de la vulnérabilité d'une zone inondable située au Bangladesh. Les données de l'occupation du sol, des types de sols, le modèle numérique de terrain, la géométrie de la rivière ainsi que des indicateurs socio-économique comme la population ont été associés pour construire les modèles de simulation hydrologique et hydraulique pour l'évaluation de la vulnérabilité et l'élaboration des cartes de risque d'inondation. Les modèles ont été calés et validés et les résultats obtenus ont indiqué que les zones de risque évaluées sont à peu près cohérentes avec la distribution globale des propriétés et le potentiel de risque d'inondation dans la zone d'étude. Les résultats de cette étude sont également précieux pour le développement de stratégies d'adaptation et de systèmes d'alerte précoce aux inondations.

II.2.3. L'évaluation du risque d'inondation

L'évaluation du risque d'inondation est donc effectuée à travers l'analyse de l'aléa et de la vulnérabilité, soit indépendamment ou combinées dans des approches qui intègrent les deux composantes. En général, le risque globale d'inondation est évalué selon deux approches : la première méthode consiste à évaluer le risque d'inondation d'une manière absolue ; par exemple en fonction des dommages attendus (figure I.6) (Coburn et al. 1994), tandis que la deuxième méthode évalue le risque d'inondation d'une manière relative par une échelle ordinale.




Figure I.6. Méthode d'évaluation du risque d'inondation absolue - dommage en fonction de la probabilité (FLOODsite 2006).

Plusieurs méthodes ont été proposées dans ce cadre, par exemple, la méthode Inondabilité élaborée à la suite des dommages causés par les inondations en Europe de l'Ouest et en France. Cette méthode propose une analyse cohérente du risque d'inondation en combinant les deux aspects de l'aléa et la vulnérabilité (Chastan et al., 1995).

Il s'agit d'utiliser les deux types de modélisation (hydrologique et hydraulique) de l'évaluation du risque d'inondation dans un contexte bien défini, intégrant des concepts de nature socio-économique indispensables pour poser les bases de décisions d'aménagement aux conséquences économiques évidentes (Du et al. 2019 ; Preetha et al. 2021 ; Tamiru, Dinka 2021 ; van der Sande, de Jong, de Roo 2003 ; Zhang et al. 2022).

I.3. Apports de la télédétection pour l'étude des zones inondables et l'évaluation du risque d'inondation

Au cours des dernières décennies, la télédétection a été exploitée comme un outil puissant pour l'étude et la cartographie de l'étendue des zones inondables et l'évaluation du risque

d'inondation. L'imagerie satellitaire à haute et très haute résolution spatiale peut apporter des informations pertinentes pour détecter et extraire les zones affectées par les inondations, évaluer les dommages socio-économiques causés par ce risque et même améliorer les modèles de simulation hydraulique qui peuvent prédire la vulnérabilité aux inondations.

En effet, en raison des limites de revisite, d'angle de vue du satellite ainsi que la couverture nuageuse dans certaines zones terrestres, les prises de vues des capteurs satellitaires ne peuvent parfois être effectuées lors d'un événement quelconque ou d'un pic de crue. Donc, la cartographie des zones inondables à travers les images satellitaires optiques et radar reste une question difficile. Par ailleurs, cette richesse satellitaire peut être exploitée dans d'autres tâches et peut aussi contribuer à l'analyse et à l'évaluation du risque d'inondation d'une autre manière que la cartographie spatiale. Dans cette section, nous décrivons la contribution des outils de télédétection dans le contexte de l'étude des inondations à travers les données actives destinées à la cartographie spatiale des zones inondables et les données passives exploitées principalement pour la modélisation et la classification de l'occupation du sol des telles zones. Ainsi, la contribution des capteurs satellitaires passifs et actifs pour la mise à disposition des modèles numériques de terrain qui aident à la constitution des modèles hydrauliques.

I.3.1. Capteurs actifs pour la cartographie des zones inondables.

Les capteurs actifs peuvent intervenir dans la phase de prévention et de prédiction des inondations afin de développer des potentiels processus de gestion du risque d'inondation tout en agissant sur l'amélioration des scénarios d'événements en temps réel. En effet, les méthodes classiques ont toujours été basées sur les mesures de terrain et donc, elles demandent beaucoup de temps, de matériel, de l'intervention humaine et une chaîne d'opérations complexes. Cependant, ces méthodes restent inadéquates sous l'effet du changement climatique, la variation spatio-temporelle des caractéristiques du sol, l'humidité et les champs de ruissellement et l'évolution des processus hydrométéorologiques qui contribuent à la genèse des inondations. Aujourd'hui, la télédétection offre des données riches en informations en temps réel ce qui facilite la prise en considération de tels changements.

Les capteurs actifs tels qu'ERS-1, ERS-2, Envisat-ASAR, RADARSAT, ALOS-PALSAR, TerraSAR-X, COSMO-SkyMed, SAR (*RADAR à synthèse d'ouverture*) et Sentinel-1 sont particulièrement pertinents pour la cartographie spatiale des zones inondables en raison de leurs capacités d'acquisition de jour et de nuit et de pénétration des nuages, L'identification spatiale des étendues inondables à partir de l'imagerie satellitaire se fait typiquement par les méthodes

d'extraction des caractéristiques et de classification la détection des changements avant, durant et après les inondations (Exemple : Figure I.7).

L'objectif principal de la caractérisation spatiale des crues extrêmes par la télédétection est la gestion des inondations en temps réel, la construction et la compréhension des modèles de simulation hydraulique ainsi que leur calage et leur validation.

D'une part, les résultats de la caractérisation spatiale de l'étendue et les limites d'eau de l'inondation à partir des capteurs actifs peuvent être intégrés avec les modèles de simulation hydraulique pour le calage de ces modèles (Hostache, 2006 ; Schumann et al., 2007). Il s'agit essentiellement de l'ajustement des paramètres du modèle (tels que la rugosité de surface ou les conditions aux limites) pour améliorer l'ajustement entre les résultats des scénarios prédits par le modèle et les observations spatiales. Dans le calage, les paramètres du modèle sont ajustés pour améliorer la performance, dans le but de trouver un ensemble ou une gamme optimale de ces paramètres (Aronica et al., 2002 ; Schumann et al., 2009).

D'autre part, la cartographie spatiale peut intervenir comme source de validation des résultats issus d'un modèle hydraulique. La validation implique la comparaison des résultats du modèle avec les observations issues de la caractérisation spatiale et l'utilisation de ces résultats pour discuter l'évolution des scénarios et tirer des conclusions. Dans le processus de validation des modèles hydrauliques, des paramètres de performance et de précision sont calculés pour évaluer la performance du modèle, comparer les modèles, et mesurer les améliorations du modèle. La procédure de calage et de validation d'un modèle par le biais des données de télédétection implique plusieurs étapes communes, essentiellement, l'extraction de l'étendue des crues ou des niveaux d'eau à partir des données satellitaires et le calcul de certains paramètres métriques pour évaluer la performance et comparer les prédictions du modèle. Parfois, le processus de calage et de validation se fait à l'aide des mêmes données.

Peu d'études dans la littérature ont traité ce type de problématique en raison de la non-disponibilité des images satellitaires capturant un événement inondation, notamment dans notre région d'étude.




Figure I.7. Exemple d'une caractérisation spatiale de l'inondation du Mississippi et du Missouri en 1993 à partir d'une Image Landsat 5 TM (avant et pendant les inondations) (NASA/EO, 2005).

I.3.2. Capteurs passifs : pour la cartographie de l'occupation du sol.

En raison des difficultés liées à l'acquisition d'images lors d'un événement d'inondation, notamment dans certaines zones terrestres ou dans des zones à grande échelle spatiale, la télédétection active devient difficile à exploiter dans l'évaluation des risques d'inondations. Dans ce cadre, l'utilisation des données satellitaires passives intervient notamment pendant les démarches d'atténuation et d'évaluation des risques et la surveillance et de gestion du risque. En effet, grâce à la richesse en informations spectrales de la télédétection passive, les éléments à risque sont mieux définis et par conséquent, cela permet de mieux évaluer leur vulnérabilité en termes de dommages. Ainsi, la connaissance des éléments présents dans une zone à risque permet une évaluation détaillée des effets réels produits sur le terrain par l'inondation. C'est pourquoi, l'objectif essentiel de la télédétection passive est d'extraire les éléments spatiaux sur une plaine inondable dans la rivière ou des chemins d'écoulement, des réservoirs, et des

conditions aux limites pourraient être conçues à partir de ces informations spatiales (Maurel et al., 2006; Raclot, 2006). En ce sens, l'exploitation des images satellitaires passives dans le contexte d'inondation repose particulièrement sur la cartographie ou la modélisation de l'occupation et l'utilisation des sols dans une zone inondable. Les cartes de l'occupation du sol sont élaborées grâce à l'utilisation de techniques de classification d'images supervisées fondées sur les approches de reconnaissance d'objets.

En outre, la modélisation de l'occupation du sol représente une base de données indispensable dans le processus de l'analyse de la vulnérabilité aux inondations. En réalité, les informations cartographiques standard peuvent ne pas avoir été mises à jour et les mesures in situ prennent généralement beaucoup de temps et peuvent être non fiables, à cause, de l'évolution temporelle des zones urbaines et bâties. Alors, la télédétection par satellite offre une approche réalisable pour éliminer ou atténuer ces limitations, en raison de sa capacité d'observation distribuée dans l'espace et de l'opportunité d'exploiter des méthodes avancées d'analyse d'images. En particulier, l'information sur l'occupation du sol est une donnée importante pour les modèles de vulnérabilité.

Typiquement, à travers l'exploration de nombreuses études, les informations issues des cartes de l'occupation du sol peuvent être exploitées dans trois contextes :

I.3.2.1. Modélisation hydrologique

L'occupation du sol est potentiellement liée aux processus hydrologiques des bassins versants, la répartition et même l'évolution des éléments caractéristiques de l'occupation du sol affectent considérablement l'interception, l'évapotranspiration, l'infiltration, le débit et le ruissellement. En même temps, les changements dans de tels processus peuvent influencer la distribution et la disponibilité des ressources en eau, ceux qui sont initialement liés aux changements de l'occupation et de l'utilisation de terres. L'impact typique de ces changements s'avère explicitement lors de la quantification de certains paramètres hydrologiques tels que les bilans hydriques du sol, les indices de végétation et des cultures et le coefficient de ruissellement (Fohrer, Haverkamp, Frede 2005 ; Gebremicael, Mohamed, Van der Zaag 2019 ; Rivas-Tabares et al. 2022 ; Schulze 2022 ; Yalew et al. 2018).

I.3.2.2. Modélisation hydraulique

Le coefficient de rugosité de Manning est l'un des paramètres empiriques les plus importants en hydrologie, en hydraulique et dans d'autres domaines scientifiques et techniques liés à l'écoulement des eaux de surface. Il quantifie la résistance d'un lit de rivière au débit d'eau et

est utilisé pour prédire le ruissellement de surface à partir des canaux naturels et les plaines inondables dans les bassins versants. En fait, ce paramètre affecte d'une manière pertinente les processus de la modélisation hydraulique, en particulier, leur sensibilité au frottement lié à la surface de ruissellement, le débit et la vitesse d'écoulement. Egalement, le calcul du temps de concentration, la détermination de la vitesse d'écoulement et la simulation des hydrogrammes de ruissellement nécessitent l'utilisation de coefficients de rugosité hydraulique (Gilley et Finkner, 1991). En effet, la rugosité est souvent calculée par des formules empiriques classiques depuis des décennies. Néanmoins, ces formules sont complexes et nécessitent plusieurs paramètres hydrauliques également complexes. Selon (Werner *et al.*, 2005), dans les terrains complexes à l'échelle des bassins versant, ces formules semblent inappropriées.

En outre, plusieurs facteurs influencent la résistance à l'écoulement sur les surfaces terrestres, à savoir, le frottement sur la surface du sol, les surfaces végétales, les résidus de culture et les roches à la surface et l'effet des gouttes de pluie. Les coefficients de rugosité hydraulique causés par chacun de ces facteurs contribuent donc à la résistance hydraulique totale. Voilà pourquoi les cartes de l'occupation et de l'utilisation du sol en plus de leurs intérêts pour la modélisation et le ruissellement peuvent être également utilisées pour assigner la rugosité hydraulique aux zones d'écoulement de surface.

Par ailleurs, les outils de télédétection et les approches de classification de l'occupation du sol présentent une solution convenable pour l'identification facile de la rugosité des plaines inondables y compris des lits mineur et majeur des cours d'eau. Et donc, des valeurs initiales de rugosité peuvent être assignées en fonction des classes de l'occupation du sol, principalement pour configurer le modèle de simulation, et être ensuite ajustées par calibration. Lors du développement de ces cartes de paramètres initiaux, l'attribution de valeurs de paramètres relativement lisses par rapport aux valeurs rugueuses est plus importante que l'exactitude des valeurs attribuées (Preetha *et al.* 2021 ; Yalcin 2020 ; Van der Sande, de Jong, de Roo 2003).

I.3.2.3. L'évaluation de la vulnérabilité

L'évaluation des dommages causés par un événement inondation nécessite une caractérisation spatiale préalable de la vulnérabilité des régions touchées par les inondations. L'occupation du sol est un facteur essentiel qui affecte la vulnérabilité aux inondations. C'est un indicateur hydrologique, hydraulique et socio-économique qui peut être intégré dans les systèmes de gestion du risque d'inondation. L'occupation du sol a un impact direct sur la zonation, l'étendue et l'intensité des inondations, modifiant ainsi la dynamique de la

vulnérabilité aux inondations (Du et al., 2019 ; Mård et al., 2018 ; Mustafa et al., 2018 ; Preetha et al., 2021). Par conséquent, l'intégration des informations spatiales de l'occupation du sol aux limites prédites de l'aléa inondation permet de visualiser les changements temporels liés à l'évènement et de quantifier les classes d'occupation du sol inondée à travers des calculs statistiques. En outre, cette vulnérabilité spatiale peut être intégrée avec d'autres indicateurs de vulnérabilité pour contribuer à la quantification des dommages en produisant des résultats cartographiques détaillés. Ces résultats peuvent soutenir les autorités pour la gestion du risque d'inondation.

I.3.3. Capteurs actifs et passifs pour la génération des modèles numériques de terrain

Les Modèles Numériques de Terrain (MNT) sont un composant clé pour l'analyse et l'évaluation du risque d'inondation qui peuvent influencer à la fois la simulation hydraulique des crues et l'étendue résultante de la crue simulée. Les données topographiques interviennent particulièrement dans la phase de constitution d'un modèle hydraulique et de détermination de l'aléa inondation. L'acquisition des données précises d'élévation sur le terrain et les relevés GPS (*Global Positioning System*) sont très coûteux, longs et difficiles à réaliser dans nombreuses régions et terrains complexes ou l'accès au cours d'eau est véritablement difficile. Par conséquent, les progrès technologiques récents des capteurs satellitaires optiques et radar ont permis permis d'acquérir des modèles numériques de terrain avec une grande précision. Cette solution alternative est fréquemment adoptée dans la plupart des études de modélisation hydraulique, par exemple, (Annis et al., 2020 ; Casas et al., 2006 ; Das and Lindenschmidt, 2021 ; Ettritch et al., 2018 ; Fathy et al., 2019 ; Lamichhane and Sharma, 2018 ; Mihiu-Pintilie et al., 2019). Ces études utilisent principalement les modèles provenant de LIDAR (*Light Detection and Ranging*), SRTM (*Shuttle Radar Topography Mission*), ASTER (*Advanced Spaceborne Thermal Emission and Reflection Radiometer*) (Tachikawa et al., 2011), CDEM (*Canadian Digital Elevation Model*), UAV (*Unmanned Aerial Vehicle*) et ALOS (*Advanced Land Observing Satellite*) (Zhang et al., 2019). De même, ces modèles sont très utilisés pour de nombreuses applications telles que l'extraction des paramètres du terrain pour la géomorphologie, l'hydrologie, les mouvements de masse et la modélisation de l'écoulement de l'eau. ALOS et ASTER sont construits à l'aide d'un processus de traitement d'images optiques, alors que le SRTM est construit sur la base du traitement de l'interférométrie radar. Les modèles ASTER et SRTM sont les modèles d'élévation les plus utilisés pour la modélisation des inondations (Grohmann, 2018). En outre, les modèles dérivés de LIDAR et UAV sont également utilisés pour les études hydrauliques et hydrologiques et offrent une résolution

spatiale très fine (jusqu'à quelques centimètres), ce qui produit plus de précisions comparativement à autres MNT (Parizi et al., 2022). Cependant, certains de ces modèles à résolution spatiale fine (par exemple le LIDAR) sont coûteux et d'autres, plusieurs zones terrestres ne sont pas dans leurs programmes de revisite.

Récemment, avec le développement des systèmes satellitaires stéréoscopiques, des capteurs de télédétection peuvent fournir des images optiques stéréoscopiques produisant ensuite des modèles numériques d'élévation. Parmi ceux-ci, le système Pléiades et son avantage stéréoscopique offrent des modèles numériques de surface à très haute résolution des surfaces terrestres à terrain complexes. C'est grâce à sa capacité d'acquisition jusqu'à trois images de la même région avec un angle stéréo variant entre 6° et 28° (Bagnardi et al., 2016 ; Lacroix et al., 2015).

Ces modèles sont très peu exploités pour la modélisation hydraulique des inondations en raison de leur lancement récent et leur condition d'acquisition. Dans ce sens, par exemple, (Bennani et al., 2019) ont analysé le risque d'inondation dans une région semi-aride au Maroc en utilisant les données topographiques provenant de Pléiades tri-stéréo. Les résultats de cette étude ont montré que ces modèles sont adéquats pour les simulations hydrauliques et offrent de grandes opportunités pour la cartographie des risques d'inondation dans les terrains complexes, ainsi la disponibilité récente de ces données d'élévation à très haute résolution, permet de mettre en œuvre l'approche de la simulation hydraulique dans différents bassins versants pour produire des cartes précises des plaines inondables.

Conclusion

L'état de l'art dressé dans ce chapitre a décrit principalement les méthodes d'évaluation du risque d'inondation et la contribution des capteurs satellitaires optiques et radar pour l'étude des zones inondables. L'évaluation du risque représente l'ensemble des approches et des techniques destinées à l'analyse quantitative et qualitative du risque en agissant sur ses deux composantes « aléa » et « vulnérabilité ».

À travers la synthèse bibliographique établie, quelques conclusions peuvent être tirées :

- Dans l'analyse de l'aléa, deux étapes principales sont considérées : l'estimation des débits maximums annuels pour différentes probabilités de dépassement et l'estimation des niveaux d'eau pour les débits maximums annuels déterminés. La première étape est la réalisation d'une modélisation hydrologique et la seconde implique une modélisation hydraulique. Les modèles hydrologiques sont développés pour évaluer l'interaction

entre l'eau, l'occupation du sol, le sol et le changement climatique. Deux paramètres essentiels sont envisagés dans ces modèles ; la pluie et le débit. Dans d'autres terrains complexes, la topographie, la géologie et les nappes aquifères sont également des paramètres nécessaires à prendre en compte. En matière de modélisation hydraulique, l'objectif principal est d'améliorer la compréhension de l'aléa pour une gestion fiable des inondations. La modélisation des inondations implique le développement d'algorithmes utiles pour caractériser les inondations en termes de profondeur et d'étendue des eaux de crue ainsi que de vitesse d'écoulement.

- Quand la zone inondable comprend une urbanisation non planifiée, une évolution rapide de l'occupation du sol et une non-planification du risque en lui-même, il est primordial d'évaluer la vulnérabilité de ces zones. L'objectif est de mieux connaître l'ampleur du risque global d'inondation à travers la combinaison de différents aspects hydrauliques et socio-économiques pour la quantification des dommages causés par les risques d'inondation.
- Le grand développement en matière d'outils de télédétection actifs et passifs a permis d'apporter des informations pertinentes pour détecter et extraire les zones affectées par les inondations, d'évaluer les dommages socio-économiques causés par ce risque et même d'améliorer les modèles de simulation hydraulique qui peuvent prédire la vulnérabilité aux inondations. Les capteurs actifs peuvent intervenir dans la phase de prévention et de prédiction des inondations afin de développer des potentiels processus de gestion du risque d'inondation tout en agissant sur l'amélioration des scénarios d'événements en temps réel. Dans un premier temps, les résultats de la caractérisation spatiale de l'étendue et les limites d'eau de l'inondation à partir des capteurs actifs peuvent être intégrés aux modèles de simulation hydraulique pour le calage de ces modèles. Ensuite, la cartographie spatiale est considérée comme source de validation des résultats issus d'un modèle hydraulique. La validation implique la comparaison des résultats du modèle avec les observations issues de la caractérisation spatiale et l'utilisation de ces résultats pour discuter l'évolution des scénarios et tirer des conclusions. Tandis que l'exploitation des images satellitaires passives dans le contexte d'inondation repose particulièrement sur la cartographie ou la modélisation de l'occupation et l'utilisation des sols dans une zone inondable. Les cartes de l'occupation du sol sont élaborées grâce à l'utilisation de techniques de classification d'images supervisées fondées sur les approches de reconnaissance d'objets. Les informations issues des cartes de l'occupation du sol peuvent être exploitées dans trois contextes :

modélisation hydrologique, modélisation hydraulique et évaluation de la vulnérabilité au risque d'inondation.

- Les capteurs passifs et actifs peuvent également fournir des modèles numériques de terrain de la topographie de cours d'eau et de la plaine inondable. Les modèles numériques de terrain sont un élément indispensable qui intervient dans la constitution d'un modèle hydraulique et la détermination de l'aléa inondation et peuvent influencer à la fois la simulation hydraulique des crues et l'étendue résultante de la crue simulée.
- À partir de résultats de synthèse bibliographique établie et les conclusions retenues à travers ce chapitre, cette thèse est replacée dans le contexte de l'étude du risque d'inondation sur ses deux composantes à partir des données satellitaires optiques et radar. Compte tenant la complexité de la zone d'étude et les problèmes liés au risque d'inondations tels que la non-planification, l'évolution de l'occupation des zones inondables et les données disponibles, la contribution principale de la télédétection est d'élaborer des cartes précises de l'occupation du sol qui contribuent la modélisation hydraulique et la caractérisation de l'aléa. Ensuite, les informations pertinentes de l'occupation du sol seront utilisées pour quantifier la vulnérabilité et l'élaboration des cartes du risque global.

À la lumière de ces objectifs, il paraît particulièrement déterminant de développer des approches méthodologiques de traitement d'images satellitaires pour la classification de l'occupation du sol et l'élaboration des cartes précises d'occupation du sol.

Le chapitre suivant est donc destiné à la mise en place d'une synthèse bibliographique de méthodes de traitement et classification des données satellitaires optiques et radar pour la modélisation de l'occupation du sol.

Partie I : ETAT DE L'ART

Chapitre II

ÉTUDE ET CLASSIFICATION DE
L'OCCUPATION DU SOL DES ZONES
INONDABLES PAR TELEDETECTION
ET METHODES D'APPRENTISSAGE
AUTOMATIQUE.

CHAPITRE II: ÉTUDE ET CLASSIFICATION DE L'OCCUPATION DU SOL DES ZONES INONDABLES PAR LA TELEDETECTION ET METHODES D'APPRENTISSAGE AUTOMATIQUE

Introduction

La modélisation de l'occupation du sol dans les zones côtières est un composant fondamental de la surveillance et de la gestion de l'environnement. En effet, les informations sur l'occupation du sol constituent des bases de données pour plusieurs applications environnementales, notamment la planification urbaine, la durabilité agricole et l'évaluation des risques naturels dans les zones côtières. En outre, les informations de l'occupation du sol fréquemment mises à jour à des échelles spatiales précises sont nécessaires pour assurer les objectifs de développement durable (Li *et al.*, 2020).

Les zones côtières revêtent une importance particulière en raison de leur situation géographique stratégique et de leurs écosystèmes naturels. En conséquence, les données de l'occupation du sol deviennent de plus en plus utiles dans les villes côtières pour la surveillance des interventions humaines telles que : l'augmentation de l'incursion agricole et de l'expansion urbaine en raison de la croissance démographique.

Au cours des dernières décennies, une plus grande attention a été accordée à l'imagerie de télédétection pour identifier les caractéristiques de l'occupation du sol avec le développement et avancées technologiques de différents capteurs satellitaires.

Par ailleurs, les capteurs de télédétection à différentes résolutions spatiales, passifs ou actifs, sont de plus en plus utilisés dans l'analyse cartographique et la modélisation de l'occupation du sol basée sur des concepts de classification et des techniques d'apprentissage automatique (*Machine Learning*) (Mantero *et al.*, 2005 ; Herold *et al.*, 2003).

De même, les techniques d'apprentissage en profondeur (*Deep Learning*) pour la modélisation de l'occupation du sol ont fait l'objet d'une attention particulière au cours de la dernière décennie. Les modèles de Deep Learning sont conçus pour résoudre diverses difficultés dans le processus de traitement des images satellitaires (Belgiu *et Csillik*, 2018 ; Wang *et al.*, 2018).

Dans cette optique, ce chapitre vise à représenter les techniques de Machine et Deep Learning dédiées à la modélisation de l'occupation du sol. Le présent chapitre est organisé en quatre sections, dont, la première section est consacrée à la représentation des capteurs de télédétection

destinés à la modélisation de l'occupation du sol. La deuxième section est dédiée à la représentation des méthodes de Machine Learning pour la classification de l'occupation du sol. Les algorithmes de classification sont décrits dans la troisième section. La quatrième section représente la classification de l'occupation du sol par la méthode de Deep Learning basée sur les Réseaux de Neurones à Convolution (*Convolutional Neural Networks : CNN*) combinés avec la méthode la méthode d'analyse d'image orientée (*Object Based Image Analysis : OBIA*). Une synthèse des méthodes d'évaluation de la performance de l'occupation du sol est établie dans la dernière section.

II.1. Télédétection et capteurs de télédétection pour la modélisation de l'occupation du sol

Au cours des deux dernières décennies, une plus grande attention a été accordée à l'imagerie de télédétection appliquée à la détection des éléments de l'occupation du sol. En effet, la possibilité offerte par la télédétection spatiale d'observer en permanence la surface de la terre a permis de créer une base de données à grande échelle. Cette base de données fournit des informations sur l'état des ressources naturelles, les écosystèmes locaux et leur développement et une surveillance étendue de l'occupation du sol (Jucker et al., 2017).

II.1.1. Définition de la télédétection

La télédétection spatiale (*Remote Sensing*) est un domaine scientifique qui intègre un large éventail de compétences et de technologies utilisées pour observer, analyser et interpréter les phénomènes terrestres et atmosphériques. Ses principaux moyens d'information sont les mesures et les images acquises à partir de plates-formes aériennes et spatiales.

En effet, la télédétection est l'acquisition de l'information à distance, sans contact direct avec l'élément étudié, dont, le porteur de cette information est un rayonnement électromagnétique entre l'élément et le capteur satellitaire.

La première apparition de la télédétection a eu lieu en 1890 sous forme d'une photographie de la surface de la terre depuis un ballon de Tournachon (Cavalais, 1991). Le premier satellite de télédétection destiné à l'observation de la terre est TIROS-I en 1960 (House et al., 1986).

Au fil du temps, des changements majeurs ont été observés dans les systèmes de télédétection actuels, en comparaison avec les techniques développées au début de l'apparition de cette technologie d'observation à distance. En particulier, l'évolution des systèmes de télédétection a été observée essentiellement dans la surveillance de l'interaction terre-atmosphère et ses grands impacts sur la terre, tels que le changement climatique, les événements extrêmes, la déforestation, la désertification, etc. (Ustin et al., 2009; Yang et al., 2013).

Cependant, de multiples capteurs de télédétection sont disponibles aujourd'hui mises en service pour émettre le signal électromagnétique sur pratiquement tout le globe terrestre. Plus particulièrement, les capteurs de télédétection avec des caractéristiques spectrales et des résolutions spatiales allant de 0,15 à 5 000 m ont un grand potentiel pour étudier et analyser l'évolution spatio-temporelle de l'occupation du sol.

II.1.2. Classement des capteurs de télédétection

II.1.2.1. Selon la résolution spatiale (Tableau II.1)

La résolution spatiale est un élément indispensable de performance pour les dispositifs de télédétection. En effet, avec la résolution spatiale peut être utilisée pour quantifier la valeur de l'information dérivée des capteurs satellitaires.

Étant donné, selon le Sous-Comité scientifique et technique des Nations Unies, la résolution spatiale est la capacité à distinguer deux cibles ponctuelles ; taille de l'image floue d'une source ponctuelle (Forshaw et *al.*, 1983). Conformément à la résolution spatiale et selon (Franklin et Wulder, 2002), on peut distinguer :

- Imagerie à faible résolution spatiale : 30 - 1000 m : Ces images sont généralement destinées à étudier des phénomènes qui peuvent être supérieurs à 100 ou 1000 mètres (à petite échelle) et peuvent être pris en charge avec les capteurs satellitaires : GOES, NOAA AVHRR, EOS MODIS, SPOT VEGETATION.
- Imagerie à résolution spatiale moyenne : 10 - 30 m: ces capteurs sont optimaux pour l'extraction de l'information qui peut évoluer généralement sur 10 ou 100 mètres (moyenne échelle) avec des images de capteurs tels que Landsat, SPOT, IRS, JERS, Plateformes ERS et RADARSAT.
- Imagerie à haute résolution spatiale (HRS) : 2 – 10 m : les applications optimales sont l'étude de phénomènes dont l'échelle peut varier sur quelques mètres (grande échelle), actuellement supportée par les plateformes de télédétection aérienne, IKONOS, Sentinel, et des applications très spécifiques des images satellitaires à grande résolution nécessitant un pixel grossier.
- Imagerie à très haute résolution spatiale (THRS) : <2 m : Ces images sont idéales pour les applications à très grande échelle qui peut varier du centimètre jusqu'à 1 ou 2 mètres, ou l'extraction de l'information est à haut niveau de résolution spatiale.

Tableau II. 1. Classement des capteurs satellitaires selon la résolution spatiale.

	Echelle de reconnaissance	Echelle Semi-détaillée	Echelle détaillée	Echelle très détaillée
Résolution	Faible résolution	Moyenne-résolution	Haute résolution	Très haute résolution
Valeur de résolution	1km -250 m	100 m-15 m	10 m-2 m	< 2 m
Capteurs			SPOT-HRG(XS+PAN)	
			QUICKBIRD	
		LANSAT-TM	IKONOS	
	NOAA- AVHRR	LANDSAT-ETM+	CASI	Lidar
	TERRA-MODIS	LANDSAT-MSS	AHS	UAV
	AQUA-MODIS	SPOT-HRV(SPOT4)	CHRIS-PROBA	PLÉAIDES
	SEAWIFS-ORBVVIEW	TERRA-ASTER	SENTINEL-1	
	MERIS-ENVISAT	IRS-LISS	SENTINEL-2	
	DMSP-OLS	IRS-WIFS	SPOT 6	
			PLÉAIDES	
		CHRIS-PROBA		
		TERRASAR-X		

Dans ce contexte, en tenant compte de la résolution spatiale, de nombreux travaux scientifiques ont été menés pour modéliser l'occupation du sol grâce à des données satellitaires de différentes résolutions spatiales. Les premiers défis ont été concentrés sur la production des modèles globaux de l'occupation du sol, dont l'échelle est très fine. Par exemple, la carte cartographique de l'occupation de 1 km (« Geosphere-Biosphere Programme Data and Information System Cover (IGBP-DISCover) ») a été réalisée avec des composites mensuelles des bandes de l'indice de végétation différentielle (NDVI) dérivé à partir des images satellitaires de 1992 à 1993 de l'agence administrative nationale « National Oceanic and Atmospheric Administration ».

Les données spatiales étaient disponibles avec une radiométrie de très haute résolution (Loveland *et* Belward, 1997). La production de cette carte a été assurée par le biais de la méthode de classification non supervisée (Lee *et al.*, 1999 ; Olaode *et al.*, 2014).

Parallèlement, (Bartholomé *et* Belward, 2005) ont exploité les données spatiales dérivées de Satellite Pour l'Observation de la Terre (SPOT) pour la réalisation d'une carte mondiale de l'occupation du sol « The 1 km Global Land Cover 2000 (GLC2000)».

De même, des composites mensuels des données NDVI ont été établis de l'année 1999 à 2000 ainsi que multiples algorithmes ont été exploités pour la production de GLC2000. La base de données GLC2000 à l'échelle de globe terrestre a utilisé un système LCCS pour la nomination des classes, ce système a été développé par l'organisation des Nations unies pour l'alimentation et l'agriculture (FAO) (Fao, 2002) et a été approuvé comme une norme unique universelle pour la classification de l'occupation du sol.

En outre, (Gong et al., 2013) ont produit les premières cartes de l'occupation du sol à l'échelle mondiale à 30 m de résolution spatiale au moyen des données Landsat Thematic Mapper (TM) et Enhanced Thematic Mapper Plus (ETM+). Les données spatiales Landsat TM et ETM+ acquises durant la saison verte couvraient la majorité de la surface terrestre. Des algorithmes de modélisation ont été développés pour la classification de l'occupation du sol. (Franklin et Wulder, 2002) ont exploité les données satellitaires à moyenne résolution spatiale pour la classification de l'occupation du sol sur de vastes régions.

II.1.2.2. Selon la source de rayonnement

- **Capteurs passifs**

Ils ne peuvent détecter l'énergie réfléchie que lorsque le Soleil illumine la Terre. Ils ne brillent pas sur la cible, ils ne peuvent que recevoir l'énergie émise ou diffusée par la cible. En effet, le domaine passif contient essentiellement des images dites optiques et thermiques. Les capteurs optiques traitent les ondes électromagnétiques dans les gammes : visible, proche infrarouge et moyen infrarouge (PIR-MIR) du spectre électromagnétique. Les capteurs thermiques captent le rayonnement émis par la surface de la terre.

- **Capteurs actifs**

Les capteurs actifs produisent leur propre source de rayonnement électromagnétique. Le domaine actif concerne les images dites RADAR (*Radio Detection And Ranging*) et les images LIDAR (*Light Detection And Ranging*). Les images Radar fonctionnent à l'aide d'ondes centimétriques qui correspondent à la partie micro-onde du spectre électromagnétique. De même que les satellites optiques, les capteurs lidar traitent les ondes électromagnétiques qui appartiennent aux gammes spectrales visible, PIR et MIR. Il est à noter, que contrairement à la télédétection optique, les domaines actifs qui utilisent la région des micro-ondes du spectre électromagnétique ont une très faible sensibilité aux conditions atmosphériques. Sachant que, les images radar peuvent être prises de jour comme de nuit même en temps nuageux (Figure II.1).




Figure II. 1. Fonctionnement des systèmes de télédétection active et passive (E : Rayonnement, T: Transmis, R : Réfléchi, A : Absorbé, D : Diffusé).

II.2. Etat de l'art sur l'utilisation des capteurs de télédétection pour la modélisation de l'occupation du sol

L'occupation et l'utilisation du sol à l'échelle mondiale évolue et rapidement en raison des activités humaines (telles que l'expansion agricole et l'urbanisation) due à la croissance démographique.

De même, les changements climatiques ont une incidence sur les processus naturels et engendrent des événements extrêmes (comme les inondations). De tels changements affectent la vie humaine et requièrent des mécanismes de suivi actifs pour la gestion et l'utilisation durables des ressources naturelles (forêts, eau, etc.) (Hansen et al., 2000 ; Phiri et al., 2020). Le développement de la télédétection satellitaire a révolutionné les approches de l'étude des ressources naturelles et humaines à la surface de la planète. Cette technologie rend possible la surveillance de vastes zones.

En effet, la communauté scientifique a eu accès à plusieurs satellites, tant commerciaux (par exemple : IKONOS, SPOT, Pléiades) que non commerciaux (par exemple, Landsat, Sentinel), depuis le lancement du premier satellite, destiné à surveiller la surface de la Terre (Landsat 1) le 23 juillet 1972 (Haack, 1982).

Aujourd'hui, les produits provenant de divers capteurs d'observation de la Terre par satellite sont largement disponibles.

La télédétection permet également de recueillir de nombreuses données et, selon le type de capteur, autrement dit, des capteurs optiques/radar, les paramètres de collecte de données, les données et les indicateurs qui en sont dérivés sont différents.

Une attention particulière est accordée à la télédétection optique et radar, en donnant des exemples sur chaque capteur, notamment les plus couramment utilisés pour la modélisation et la cartographie de l'occupation du sol.

La Figure II.2 représente une illustration de la chronologie des mises en service et heures de fonctionnement des satellites optiques et radar d'observation de la Terre. Il est à noter que la longueur de la flèche représente la continuité et la durée du programme satellite correspondant (Rumiano, 2021).

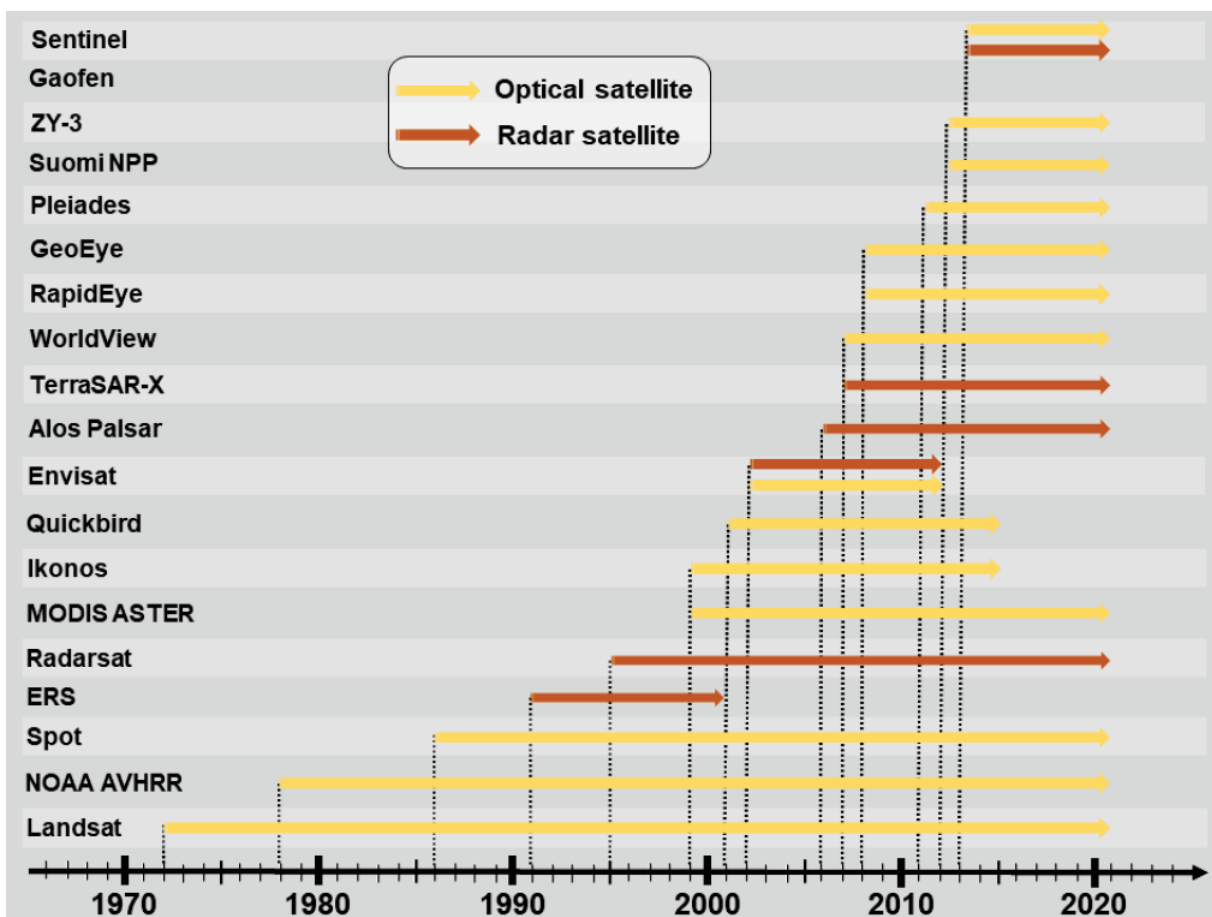


Figure II. 2. Chronologie des mises en service et heures de fonctionnement des satellites optiques et radar d'observation de la Terre. La longueur de la flèche représente la continuité et la durée du programme satellite correspondant (Rumiano, 2021).

II.2.1. Télédétection optique

Les capteurs d'imagerie optique sont des capteurs aérospatiaux qui captent une partie du rayonnement solaire réfléchi par la surface de la Terre. Chaque capteur optique comporte une

bande spectrale fonctionnelle (les plages spectrales optiques sont "visibles", "PIR" et "MIR").

La gamme spectrale de l'optique est la suivante :

- De 0,4 μm à 0,7 μm pour le spectre visible ;
- De 0,7 μm à 3,0 μm pour le spectre proche et moyen infra rouge (signature spectrale de la végétation, de l'humidité des sols) ;
- 4 μm à 50 μm pour le spectre infrarouge thermique.

Les rayonnements émis par le soleil parcourent l'atmosphère, interagissent avec la surface terrestre avant d'être réfléchis à partir de cette surface pour être enregistrées par le capteur. Cette radiation sera traitée par le détecteur afin de réduire les effets atmosphériques.

Lorsque le rayonnement électromagnétique atteint un objet à la surface, une partie de l'énergie est absorbée et une autre partie du rayonnement est réfléchi par l'objet. Une partie du rayonnement peut traverser un objet lorsqu'il est plus ou moins transparent, et la réfraction peut le détourner. Le coefficient de réflectance, appelé réflectance, est le pourcentage d'énergie réfléchi par la surface d'un objet. Cela dépend du type et des propriétés uniques de l'objet et de la surface, ainsi que de la longueur d'onde.

Les mesures effectuées au niveau du capteur dépendent de la quantité de rayonnement solaire, des conditions atmosphériques, des conditions de surface et de la géométrie acquise (la position du soleil et du capteur). Avec une modélisation appropriée, le cas échéant, la réflectance peut être dérivée de mesures dans le plan du capteur.

La courbe qui représente la variation de la réflectance avec la longueur d'onde est appelé la signature spectrale. C'est la principale donnée dérivée de la télédétection qui caractérise une surface. De plus, le choix des canaux dans l'imagerie multi-spectrale est basé sur cette signature spectrale. Si une image est acquise dans une seule large bande couvrant toute la gamme visible, on l'appelle une **image panchromatique**.

En outre, l'acquisition d'images à partir de capteurs optiques est caractérisée par trois types de résolution : spatiale, spectrale et temporelle :

- **La résolution spatiale** : correspond à la zone de balayage des éléments instantanément observée par le capteur. Avec les capteurs optiques, il est courant de simplifier l'approche et de confondre cette zone de base avec la taille des pixels.
- **La résolution temporelle** ou période de revisite : correspond au temps entre deux prises de vue d'une même scène à un point précis de la Terre. Cette caractéristique ne dépend pas du capteur, mais de l'orbite du satellite et du mode de commande. La résolution

temporelle des images varie de quelques jours à plusieurs mois (fortement dépendante des capacités de dépointage du capteur particulier).

- **La résolution spectrale** : correspond aux bandes de longueurs d'onde auxquelles les capteurs sont sensibles.

En revenant à la littérature, selon (Joshi et al. 2016), depuis plus de 40 ans, la télédétection optique a fourni des données satellitaires optiques, avec quelques systèmes dominant les analyses de l'occupation du sol, en raison de la cohérence et la disponibilité des données (Landsat 1 depuis 1972, Landsat Thematic Mapper (TM) depuis 1983, le SPOT depuis 1980 et le satellite MODIS (*the Moderate Resolution Imaging Spectroradiometer*) depuis 1999. De même, les satellites influencés par la constellation, comme le programme Copernic 1 possèdent une composante spatiale qui fournit des images libres à haute résolution spatiale (HRS) et temporelle couvrant une large gamme spectrale.

Dans la plupart, et dans sa gamme optique, l'imagerie Sentinel-2 fournit une imagerie optique et infrarouge moyen tous les 5 jours avec une résolution jusqu'à 10 mètres. A l'échelle régionale ou nationale, les applications de la modélisation de l'occupation du sol exploitent souvent les données ayant une moyenne/haute résolution spatiale (< 100 m) (par exemple, SPOT ou Landsat). Les développements récents de la puissance de calcul et des techniques d'exploitation des données satellitaires ont permis d'exploiter ces données à l'échelle mondiale. Aussi, des données de résolution spatiale modérée à faible (>250 m) ont été utilisées pour l'analyse et la cartographie mondiale de l'occupation du sol, notamment : le satellite MERIS (*the Medium Resolution Imaging Spectrometer* pour GLOBCOVER, le SPOT pour la cartographie de la végétation (2000), les données issues de AVHRR (*the Advanced Very High Resolution Radiometer*) pour la cartographie de l'occupation du sol (Maryland Global Land Cover Classification, et aussi le MODIS. Grâce à la disponibilité d'informations sur l'occupation du sol à l'échelle mondiale, régionale et même nationale, la communauté scientifique a accès à des bases de données essentielles pour d'autres applications environnementales. De plus en plus, les études examinent des techniques qui analysent des séries chronologiques denses de données optiques ou les intègrent aux données statistiques explicites dans l'espace, pour suivre phénomène précis.

Le principe de ces techniques est l'exploitation d'une large quantité de données optiques librement disponibles, notamment, les archives Landsat. Par rapport à la classification d'images multitemporelle traditionnelle, l'analyse de séries chronologiques denses peut capturer des processus de changement hautement dynamiques, graduels ou à long terme et réduire les lacunes de la couverture nuageuse (Phiri et al. 2020).

II.2.1.1. Quelques exemples des captures optiques

▪ Landsat

La modélisation de l'occupation du sol à l'aide des images Landsat a évolué au cours des quatre dernières décennies. Avec le programme Landsat en cours, différentes méthodes de classification de l'occupation du sol ont été développées. Le développement de ces méthodes a contribué de manière significative à l'amélioration de l'imagerie Landsat, aux progrès de la technologie informatique, au développement des Systèmes d'Information Géographique (SIG) et à la politique d'accès libre de Landsat (Phiri et Morgenroth, 2017).

Par ailleurs, les données optiques Landsat TM/ETM+ sont largement utilisées pour la classification de la couverture terrestre en raison de leur coût relativement faible, de leur longue histoire et de leur archivage fréquent. Ceci est d'autant plus important parce que l'information sur l'évolution temporelle et spatiale de l'occupation du sol est une exigence fondamentale pour la surveillance de l'environnement et la prévention des impacts environnementaux négatifs. Pour construire des compositions annuelles en séries temporelles denses, (White et al., 2014) ont exploité les données de l'archive Landsat. Les sélections ont été faites en fonction de la distance et du pourcentage de couverture nuageuse à partir de jours d'intérêt spécifiques pour l'année.

L'objectif était d'utiliser les informations obtenues à partir des produits satellitaires dans le cadre de la surveillance des écosystèmes forestiers canadiens à l'échelle nationale. L'approche proposée utilise les composites annuelles a été appliquée en deux zones prototypes en exploitant une archive de 15 ans de données Landsat.

Les résultats de cette étude suggèrent que l'approche basée sur les séries chronologiques de Landsat est applicable à grande échelle (régionale et nationale), et que les cartes générées peuvent constituer une base de données très intéressante pour le suivi des systèmes forestiers canadiens. De même, (Alqurashi et al., 2016) analysent l'expansion de la croissance urbaine et le changement de l'occupation du sol dans cinq villes saoudiennes à l'aide d'images Landsat de 1985, 1990, 2000, 2007 et 2014. La méthode proposée était basée sur la classification de

l'occupation du sol à l'aide de techniques de télédétection et de traitement d'images satellitaires. Par conséquent, les auteurs proposaient également des prédictions d'occupation du sol pour les villes étudiées en 2024 et 2034.

(Ghayour et al., 2021) ont utilisé les données Landsat 8 OLI (*The Operational Land Imager*) pour créer des cartes d'occupation du sol par le biais des algorithmes de classification supervisée. L'objectif escompté par ce travail est de comparer les performances des algorithmes de l'apprentissage automatique. Ils ont également comparé le potentiel des données Landsat à celui de Sentinel-2. L'analyse des résultats de cette étude a montré que les classifications d'occupation du sol produites étaient de haute qualité pour les deux types de données satellitaires. Les résultats ont également montré que les données utilisées affectaient le traitement en raison de résolutions et de bandes spectrales différentes, en particulier, la précision de la classification de chaque algorithme.

La figure II.3 illustre les stations de programme Landsat sur le globe terrestre.



Figure II.3. Stations des programmes spatiaux Landsat 5 et 7.

▪ Sentinel-2

Les progrès de la télédétection par satellite ont révolutionné les méthodes de surveillance de la surface de la Terre. Le développement du programme Copernicus par l'Agence Spatiale Européenne (ESA) et l'Union européenne (UE) a contribué à la surveillance de surface de la terre grâce à la production du produit multispectral Sentinel-2. Après la mission Sentinel-1 en 2014, le satellite Sentinel-2 est la deuxième constellation de la mission Sentinel de l'ESA et est équipé d'un scanner multispectral.

L'objectif principal de la mission Sentinel-2 est de fournir des données satellitaires à haute résolution pour surveiller l'occupation du sol, le changement climatique et la surveillance des catastrophes, en complément d'autres missions satellitaires telles que Landsat (Phiri et al., 2020). La constellation Sentinel-2 est constituée de deux satellites 2A et 2B. Sentinel-2A a été lancé le 23 juin 2015 et Sentinel-2B a été lancé le 7 mars 2017.

Les deux satellites en orbite polaire de la constellation sont sur la même orbite héliosynchrone et déphasés de 180° l'un par rapport à l'autre. L'imagerie à large bande est fournie par ces deux satellites (large fauchée - 290 km) à des temps de répétition fréquents (10 jours pour un satellite et 5 jours pour les deux satellites) (Martimort et al., 2007). En termes de résolution spatiale, l'imagerie Sentinel-2 a une résolution spatiale moyenne à haute, selon le type de bande spectrale à 10, 20 et 60 mètres. Par conséquent Il est important de signaler que le produit Sentinel-2 possède 13 bandes spectrales dans les régions visibles, proche infrarouge et proche infrarouge du spectre.

Depuis son lancement, le capteur Sentinel-2 a fourni des quantités massives d'images satellitaires en libre-service pour la classification de l'occupation du sol dans le monde entier. De plus, la diversité des bandes spectrales dans le Sentinel-2 permet de dériver des indices spectraux (Segarra et al., 2020 ; Xiao et al., 2020 ; Tian et al., 2022) et de caractériser diverses composantes de l'occupation du sol telles que la végétation (Mazzia et al., 2019), l'agriculture de surface (Belgiu and Csillik, 2018 ; Kussul et al., 2017). De même, la cartographie des zones urbaines et de l'occupation du sol avec ses différents types utilisent souvent l'imagerie Sentinel-2. Par exemple, (Heryadi *et* Miranda, 2020; Lebourgeois *et al.*, 2017; Liu *et al.*, 2019b; Phiri *et al.*, 2020).

▪ Pléiades

Parmi les systèmes satellitaires THRS disponibles, nous considérons les images optiques commerciales Pléiades, couramment utilisées pour la modélisation de l'occupation du sol. Ce

premier système satellitaire européen à très haute résolution spatiale (VHR) est composé d'une constellation de deux satellites identiques, Pléiades-1A (PHR1A) et Pléiades-1B (PHR1B), lancés depuis la base spatiale européenne de Kourou, en Guyane française, par le centre national d'Etudes Spatiales (CNES), respectivement le 17 décembre 2011 et le 2 décembre 2012.

Les deux satellites volent à une altitude de 694 km sur des orbites synchrones avec une inclinaison de $98,2^\circ$ et un décalage de 180° l'un par rapport l'autre, ce qui offre une fréquence journalière de revisite. Le système Pléiades a un aspect technique particulier qui se présente dans la flexibilité de ses capteurs, ce qui permet des acquisitions fréquentes des zones d'intérêt, avec des angles stéréo variant de $\sim 6^\circ$ à $\sim 28^\circ$. Les quantités de rayonnement solaire sont presque constantes grâce à des intervalles de temps très courts (quelques secondes) entre les prises d'images le long du trajet du capteur. Cela garantit également des changements de scène limités et une couverture nuageuse similaire dans toutes les images (Piermattei et al., 2018).

De même, le capteur Pléiades fournit des images panchromatiques et multispectrales délivrées le long de la piste en stéréo (avant, arrière) et tri- stéréo (avant, nadir et arrière) à des résolutions spatiales de 0,5 m et 2 m, respectivement.

En raison des propriétés ci-dessus et de sa résolution spectrale et spatiale, l'imagerie Pléiades est largement utilisée pour la classification de l'occupation du sol grâce au développement de diverses méthodes qui mettent l'accent sur les possibilités spectrales et la flexibilité. Pour cette raison, (Pu et al., 2018) ont utilisé une collection d'images multi-saisonnières Pléiades pour classer les espèces d'arbres urbains. Les auteurs ont évalué et comparé la capacité des images Pléiades individuelles et combinées prises à différentes saisons pour classer les espèces d'arbres urbains afin de comprendre l'impact saisonnier sur la qualité de la cartographie. Pour comparaison, différents algorithmes de *Machine Learning* ont été utilisés dans les processus de classification des images. Les résultats expérimentaux ont démontré que la précision de la cartographie des espèces d'arbres à l'aide de l'imagerie satellitaire est la solution significative pour distinguer les espèces d'arbres. De plus, la combinaison de deux saisons (humide-sèche) s'est avérée excellente pour la même question. Les résultats ont suggéré l'effet saisonnier important sur la classification des espèces d'arbres.

En pratique, il est donc important de sélectionner des données saisonnières de télédétection pour cartographier les espèces d'arbres. De même, (Li et al., 2016) ont cartographié l'occupation du sol dans la ville urbaine Wuhan en Chine. Pour cela, une image Pléiades le long de cette région a été utilisée, et les auteurs ont testé une nouvelle méthode pour déterminer la distribution

spatiale des éléments de l'occupation du sol en intégrant d'autres indicateurs couramment utilisés dans l'identification des éléments d'occupation du sol. Par conséquent, les résultats de cette étude ont démontré l'avantage de l'utilisation des produits de (THRS) Pléiades pour l'extraction des éléments urbains, ainsi que l'utilisation de la nouvelle méthode intégrant les indicateurs a produit des cartes d'occupation du sol de haute qualité.

II.2.2. Télédétection radar

L'utilisation des données radar a évolué récemment dans la télédétection, principalement au cours des deux dernières décennies. Contrairement aux données optiques, les données radar ne sont pas exploitées pour la modélisation de l'occupation du sol aussi largement que la télédétection optique. En particulier, les données de nombreux systèmes SAR (Radar à Synthèse d'Ouverture) spatiaux antérieurs et actuels - radar à imagerie spatiale en bande C/X, RADAR à synthèse d'ouverture (SIR-C/X-SAR), European Remote Sensing (ERS -1 et -2), *Altitude Synthetic Aperture Radar (ASAR)*, *Earth Resources Satellite (JERS-1)*, RADARSAT-1 et -2, *Advanced Earth Observation Satellite (ALOS-1)* (Figure II.4), sont largement utilisés à l'échelle régionale, et très peu à l'échelle universelle.

Dans la littérature, l'application des données Radar porte essentiellement sur des études de classification de l'occupation du sol, l'évaluation des système forestiers, l'étude de la déforestation, la cartographie des surfaces agricoles, l'analyse des expansions urbaines ainsi que la cartographie et le suivi d'espèces végétales. Par ailleurs, leur utilisation pour la cartographie de l'occupation du sol, les données radar sont utilisées pour d'autres thématiques environnementales notamment : l'évaluation des risques et évènements extrême, les inondations, le changement climatique et les régimes de gestion des terres.




Figure II.4. Historique des capteurs Radar de 1991 jusqu'à 2020 (UNAVCO, 2018).

▪ **Sentinel-1**

Le lancement de la mission Sentinel-1 par l'Agence Spatiale européenne (ESA) a été un atout majeur pour les outils de télédétection d'observation de la Terre, offrant des capacités sans précédent pour la cartographie radar intensive de la surface terrestre. En fait, l'objectif principal de la mission Sentinel-1 est de fournir les informations vitales pour la surveillance de la terre et l'environnement marin, la gestion des crises et des catastrophes, la surveillance atmosphérique mondiale et le suivi du changement climatique et la sécurité (Lanari et al., 2020). Sachant que le radar offre la possibilité d'observer des événements environnementaux tels que des glissements de terrain (Zhou et al., 2020) et des inondations (Amitrano et al., 2018; Martinis et al., 2018).

Le capteur radar Sentinel-1 est composé d'une constellation de deux satellites : Sentinel-1A and Sentinel-1B, lancés respectivement le 3 Avril 2014 et le 25 Avril 2016. La constellation est en opération jour et nuit et utilise l'imagerie SAR acquise à une échelle globale, avec une revisite de 6 jours.

Le capteur Sentinel-1 fournit des images SAR en bande C à polarisation simple et double dans divers modes d'acquisition (Figure II.5). Une résolution spatiale élevée de 10 m en mode interféromètre à large bande, une couverture étendue (jusqu'à 400 km) et une résolution temporelle améliorée se combinent pour offrir de nouvelles opportunités intéressantes pour une cartographie précise de l'occupation du sol (Wagner et al., 2012).

Par rapport aux missions radar précédentes, le radar Sentinel-1 a un avantage significatif avec le temps de revisite fréquent (Tableau II.2), notamment pour la cartographie et l'analyse de la dynamique phénologique dans la végétation et les surfaces agricoles, ainsi que la capacité de polarisation double et l'acquisition rapide de l'imagerie (Clerici et al., 2017).

Tableau II. 2. Caractéristiques du Capteur radar Sentinel-1.

Satellite	Sentinel-1A et Sentinel-2A
Résolution spatiale	Entre 4 et 40 m
Revisite temporelle	6 jours
Fréquence	5.4 GHz
Hauteur de l'orbite	693 Km ²
Polarisation	Parallèle (HH, VV) Croisée (VV +VH, HH+ HV)
Orbite	Ascendant /descendent
Angle d'incidence	20° et 46°




Figure II.5. Les modes d'acquisitions de Sentinel-1(Sentinel-1 SAR Technical Guide (ESA).

Pour la classification de l'occupation du sol, les données satellitaires Sentinel-1 ont été principalement intégrées avec des données optiques pour améliorer la qualité de la classification. En effet, le RADAR collecte des informations même sous la couverture nuageuse, et donc offre plus d'informations. La section suivante détaille plus cet aspect.

II.2.3. Synergie optique et radar pour la modélisation de l'occupation du sol

Le développement de l'image optique dépend principalement de la couverture des nuages, l'utilisation des données d'images radar à titre d'exemple : les données SAR permet de pallier ce problème en permettant d'acquérir des données de nuit comme de jour, sans que l'amplitude du signal ne soit significativement perturbée par les conditions atmosphériques. Et donc, contrairement aux données optiques, les données SAR sont presque indépendantes des conditions météorologiques.

Les capteurs SAR avec leur caractéristique d'acquisition active et leur vue oblique, génèrent leur propre source d'énergie et le capteur reçoit l'énergie rétrodiffusée (transmise) des cibles au sol. Ainsi, la mesure du signal réfléchi permet de caractériser diverses propriétés géométriques et physiques de la surface observée liées à la rugosité, au type de matériau et à la teneur en humidité. Les données SAR permettent de fournir différents renseignements, mais complémentaires, sur l'occupation et l'utilisation des terres, comparativement aux données optiques.

Cependant, Dans le cas des données optiques, il peut être difficile de distinguer les espèces végétales en raison de leur signature spectrale similaire. Par conséquent, l'utilisation des capteurs Radar peut contribuer à une modélisation plus précise de l'occupation du sol avec des différences potentiellement significatives entre les différentes classes (Joshi et al. 2016).

La grande quantité de données actuellement générées par les missions modernes d'observation de la Terre a permis le développement de techniques avancées de télédétection et de *Machine Learning*, qui peuvent identifier des éléments complexes de l'occupation et l'utilisation des sols. En effet, les programmes et missions satellitaires récemment développés tels que Sentinel-1 et Sentinel-2 fournissent fréquemment des images radar et optiques (multispectrales) à 10 m de résolution spatiale, avec des temps de revisite d'environ 5 jours.

Cette résolution temporelle élevée permet la collecte de séries chronologiques d'images satellitaires qui prennent en charge une cartographie plus fréquente de l'occupation et l'utilisation des sols (Ienco et al. 2019). Dernièrement, les techniques avancées de la télédétection ont permis de combiner potentiellement les informations fournies par capteurs

optique et radar, ce qui assure une détection profonde de différents éléments et classes de l'occupation du sol.

Dans ce contexte, de nombreuses études ont montré que la combinaison ou la fusion des propriétés des matériaux de surface fournies par les capteurs optiques (Sentinel-2) et les caractéristiques structurelles des éléments du paysage fournis par les capteurs radar (Sentinel-1) peuvent être considérées comme deux aspects qui complètent la tâche de cartographie de l'occupation du sol.

La combinaison de données optiques et radar s'est avérée plus efficace que les capteurs individuels dans de nombreux scénarios, particulièrement, la cartographie des cultures (MCNairn et al. 2009; Van Tricht et al., 2018), la surveillance des forêts et la cartographie de l'occupation du sol (Vaglio Laurin et al., 2013), détection d'espèces d'arbres et la cartographie de la végétation (Monsalve-Tellez et al., 2022), la surveillance des zones humides (Niculescu et al., 2020 ; Whyte et al., 2018) et la cartographie des zones urbaines (Tavares et al., 2019).

Les techniques synergétiques d'images peuvent être divisées en trois catégories selon le stade auquel l'intégration est effectuée. La première correspondant à la fusion au niveau des pixels, la deuxième technique de synergie optique radar concerne la fusion des caractéristiques et enfin la fusion des décisions. Elle se réfère à la combinaison des pixels des images sources après des prétraitements de correction effectués individuellement, tandis que la seconde est basée sur la combinaison de caractéristiques extraites d'images individuelles (Huang et al., 2007 ; Stefanski et al., 2014).

En revanche, la fusion décisionnelle nécessite le traitement d'ensembles de données optiques et radar, y compris la classification des images optiques et des données SAR générées séparément pour chaque type de données, et la combinaison de ces classifications pour obtenir le résultat final (Waske et Benediktsson, 2007). Les deux premières approches peuvent être considérées comme "pré-classification ou modélisation par fusion", tandis que la dernière approche comme "post-classification ou modélisation de la fusion" (Joshi et al., 2016).

(Schulz et al., 2021) ont développé une approche synergique des données Sentinel-1 et Sentinel-2 pour générer une carte précise et haute résolution de l'utilisation des terres couvrant Niamey, la capitale du Niger et ses environs, qui se caractérise par son paysage hétérogène. L'approche de cette étude a été basée sur l'extraction des caractéristiques des images satellitaires, puis fusion avec toutes les sources de données Radar et optique utilisées dans le processus de classification qui a été assuré par des algorithmes de Machine Learning (*Random Forest* : RF, *Maximum Likelihood* : ML et *Support Vector Machine* : SVM). La précision de classification a

été évaluée avec et sans fusion des caractéristiques extraites avec les données. De ce fait, il a été démontré, que la fusion des caractéristiques spectrales de Sentinel-2 et les bandes de Sentinel-1 a fortement amélioré la qualité de classification.

(Tavares et al., 2019) ont analysé l'occupation du sol dans une région tropicale en considérant les limitations de l'exploitation des capteurs optiques à cause de la forte couverture nuageuse tout au long de l'année dans telles régions. Il est à préciser que dans cette étude les données SAR Sentinel-1 en combinaison avec l'imagerie optique Sentinel-2 ont été exploitées pour suivre et cartographier les régions tropicales. Une approche *Machine Learning* à l'aide de l'algorithme RF a été choisie pour la classification de l'occupation du sol. En outre, une attention particulière a été concédée à l'analyse diverses combinaisons de deux types de données, les indices de végétations extraits de Sentinel-2 et les caractéristiques structurelles dérivées de Sentinel-1. Au total, six classifications de l'occupation du sol ont été établies. Les résultats ont montré que la meilleure précision globale (*Overall Accuracy: OA*) a été trouvée pour l'intégration des données Sentinel-1 et Sentinel-2 (91,07 %), suivie par Sentinel-2 seulement (89,53 %) et Sentinel-2 avec des indices radiométriques (89,45 %). Les données Sentinel-1 traitées individuellement ont donné le mauvais résultat en termes de précision (OA= 56,01). Les résultats de cette application ont également montré que l'intégration d'images optiques dans différentes fusions a amélioré le OA dans toutes les classifications.

(Clerici et al., 2017) ont proposé une approche méthodologique qui intègre les informations des images Sentinel-1 et Sentinel-2 pour modéliser avec précision l'occupation du sol d'une partie de la région de la Magdalena inférieure, en Colombie. La classification de l'occupation du sol a été effectuée à l'aide d'une classification orientée objet et d'approches spectrales, et a également utilisé des indices de végétation obtenus à partir des bandes spectrales Sentinel-2. La classification a été effectuée à l'aide de trois algorithmes de classification. La classification obtenue en combinant les ensembles de données radar et optique et l'algorithme de la machine à vecteurs de support était la plus précise, avec une précision de classification globale de 88,75 %. L'étude a également montré l'intérêt de combiner les capacités des capteurs radar avec les riches informations spectrales dans le visible et le proche infrarouge fournies par Sentinel-2 pour une cartographie précise et de haute qualité de l'occupation du sol.

Malgré les différences dans les approches méthodologiques ci-dessus et celles proposées dans d'autres études, par exemple : (Chust et al., 2004; Corbane et al., 2008; Dusseux et al., 2014; McNairn et al., 2009; Peters et al., 2011; Pleskachevsky et al., 2011; Vaglio Laurin et al., 2013),

la fusion des données radar et optiques s'est avérée très bénéfique pour la modélisation et l'évaluation de l'occupation du sol et l'utilisation des terres.

Cependant, en plus de choisir l'ensemble des données appropriées et de décider comment et à quel stade fusionner différents types d'images pour la classification de l'occupation du sol, l'utilisateur peut spécifier différentes méthodologies à tester pour sélectionner la méthode la plus précise pour analyser différents type d'occupation du sol analysé (Hong *et* Wdowski, 2014).

Dans cette optique, les approches et les algorithmes de Machine Learning sont présentés comme des solutions optimales pour la classification supervisée, pour déterminer les différentes classes de l'occupation du sol pour l'ensemble de la région. Certains algorithmes Machine Learning ont été utilisés pour classer les images à faible, moyenne et haute résolution spatiale (Wald, 1999).

Les sections suivantes, décrivent les approches et les algorithmes de Machine Learning destinés à développer une classification supervisée de l'occupation du sol.

II.3. Méthodes de Machine Learning pour la classification de l'occupation du sol

La modélisation de l'occupation du sol à partir de signaux bruts de télédétection est généralement effectuée à l'aide de méthodes de classification par apprentissage automatique (*Machine Learning*). Les techniques d'apprentissage automatique sont basées sur le concept de calcul statique automatique utilisé pour construire des modèles de classification. Les données dites d'apprentissage sont utilisées pour régler ou optimiser les paramètres du modèle de classification (Tuia *et al.*, 2011).

L'apprentissage automatique consiste à générer automatiquement un ensemble de règles de classification ou d'inférence à partir d'un ensemble d'apprentissage constitué de cas déjà classés ou inférés. Ces règles sont nécessairement basées sur un nombre réduit de cas et devraient être appliquées dans un contexte plus large. Par conséquent, les applications de télédétection consistent à générer un modèle de classification sur une petite partie d'une image et à l'appliquer à l'image entière.

En télédétection, une classification des images est le processus de conversion d'objets (pixels) en information significatives. Ainsi, les images sont classifiées selon une classification supervisée ou non supervisée. Dans le cas de la classification supervisée, et selon (Chi *et al.*, 2008).

Les performances d'un algorithme de classification dépendent fortement des données d'apprentissage utilisées pour générer ce modèle. Cette limitation rend plus difficile et plus coûteuse la construction d'un ensemble de données d'entraînement efficace en termes de représentativité et de classification, rendant ainsi plus importante encore la nécessité de choisir rationnellement ces données (Tuia et *al.*, 2011). Dans ce sens, le problème d'apprentissage est basé sur trois caractéristiques :

- Choix du type et du mode d'échantillonnage,
- Choix du type des entités à classer (pixels, objets),
- Choix de l'algorithme de classification.

Le type et le mode d'échantillonnage sont déterminés par la nature du problème à résoudre et l'ensemble des données satellitaires. Ainsi, le type d'échantillonnage peut se faire par les enquêtes sur terrain, photo-interprétation ou les deux.

Le type d'échantillonnage est défini selon la manière de sélection les données d'apprentissage telle que :

- La sélection aléatoire où chaque échantillon à la même probabilité d'être sélectionné (Vempala,1997),
- La sélection aléatoire stratifiée (*Random Stratified Sampling*) où les données sont subdivisées en strate (sous-groupe) et sélectionnées en proportions (Ye et *al.*, 2013).
- La sélection localisée où les données sont dans la même zone géographique ou la sélection globale quand les données sont distantes géographiquement (Chehata et *al.*, 2015).

Deux approches de classification sont largement utilisées dans la communauté de la télédétection : l'approche par pixel et l'approche orientée objet. Nous nous concentrons ci-dessous sur ces deux approches et leurs contributions à la modélisation de l'occupation du sol.

II.3.1. Méthode Pixel par pixel

Les applications des algorithmes de classification en télédétection sont souvent basées sur des classificateurs pixel par pixel. Ces techniques classent les pixels d'image individuels dans des classes définies par l'utilisateur en fonction des propriétés spectrales identifiées de chaque pixel calculées en utilisant une entrée utilisateur minimale (non supervisée) ou des données d'apprentissage définies par l'utilisateur (supervisée). La classification de l'occupation du sol basée sur les pixels est l'une des approches de classification les plus courantes appliquée aux

image satellitaires à moyenne et HRS. Il a été démontré dans la littérature que les RF sont les classificateurs les plus couramment utilisés pour l'approche basée sur les pixels.

Cependant, le principal inconvénient de cette méthode au cours du processus de classification est que les informations spatiales, textuelles et contextuelles ne sont généralement pas prises en compte, l'aspect sel-poivre (Blaschke, 2010) ou le speckle - bruit spectral ainsi que le problème de pixel mixte existe pour certaines classes. En raison de ces limitations des approches basées sur les pixels, de nouvelles méthodes d'analyse d'images basées sur le concept des « objets » ont été développées au cours de la dernière décennie pour améliorer la qualité des informations extraites du processus de classification (Blaschke, 2010 ; Duro et *al.*, 2012)

II.3.2. Méthode Orientée Objet

L'utilisation de la méthode Orientée Object (Object Based Image Analysis : OBIA) avec les classificateurs Machine Learning est reconnue par la communauté de la télédétection comme un moyen de mieux résoudre le problème de la classification de l'occupation et l'utilisation des sols et de la détection et de leur dynamique.

Cette méthode considère les informations spectrales, textuelles et contextuelles des pixels. Les objets sont généralement un groupe discret et mutuellement exclusif de pixels adjacents, exploité comme unité de base de l'analyse spatiale. Les objets peuvent provenir de diverses sources, mais sont généralement construits par le processus de segmentation d'image. C'est pourquoi les objets sont souvent appelés segments (Blaschke, 2010).

Récemment, la classification OBIA a remplacé les méthodes traditionnelles basées sur les pixels pour faciliter la classification de l'occupation de sol à l'aide d'images de télédétection à HRS et THRS (Castillejo-González et *al.*, 2009 ; Chen et *al.*, 2012 ; Liu et *al.*, 2019b), ceci pour trois raisons principales :

- OBIA minimise la variation spectrale au sein des classes en affectant tous les pixels d'objet à une catégorie identique de l'occupation du sol (Castillejo-González et *al.*, 2009).
- OBIA fait un meilleur usage des informations spatiales contenues dans les images de télédétection, telles que la taille, la forme et la texture des objets (Blaschke, 2010 ; Tehrany et *al.*, 2014).
- OBIA facilite l'intégration des relations contextuelles et sémantiques entre les objets géographiques (Blaschke, 2010 ; Blaschke et *al.*, 2014 ; Platt et Rapoza, 2008).

La méthode OBIA est capable d'identifier les caractéristiques géographiques et les objets entrecoupés (Amini *et al.*, 2018). Selon l'approche OBIA, les objets sont extraits via le processus de segmentation prenant en compte des informations spectrales, texturales et contextuelles des pixels similaires. Récemment, cette méthode a été largement appliquée à l'évaluation et à la cartographie de l'occupation du sol au moyen de télédétection, dans divers environnements (Pande *et Banerjee*, 2021; Yin *et al.*, 2018). Dans ce sens, (Li *et al.*, 2017) ont étudié la performance des données de télédétection et des méthodes de Machine Learning pour l'évaluation de l'expansion anthropique de l'occupation et l'utilisation des terres dans la zone côtière de la province de Liaoning en Chine. Ici, OBIA a été utilisée pour effectuer la classification de l'occupation du sol appliquée aux images Landsat TM/ETM +/-OLI de 1990 à 2014, et a montré le potentiel pour surveiller les changements anthropiques de l'occupation et l'utilisation des terres au cours de la période d'analyse (comme indiqué par sa bonne précision globale (OA)). Sachant que même dans les zones côtières à basse altitude, l'OBIA a été adoptée pour la détection précise de l'occupation et l'utilisation des terres. En 2021, dans leurs travaux (Nandam *et Patel*, 2021) ont utilisé une méthode hybride basée sur l'algorithme Support Vector Machine (SVM) et des caractéristiques spectrales pour cartographier l'occupation et l'utilisation des terres dans la ville de Surat, située sur la côte ouest du Gujarat, en Inde, en utilisant les données d'imagerie des séries Landsat 5-TM, 7-EMT et 8-OLI/TIRS. En plus de l'algorithme d'apprentissage SVM choisi pour effectuer le processus de classification, des indices spectraux ont été extraits à partir des images satellites visant à améliorer la précision de la classification, y compris l'indice de végétation différentielle normalisé (NDVI), et l'indice de différence d'eau normalisé modifié (MNDWI).

Le classificateur SVM a également été comparé à RF pour évaluer l'algorithme le plus efficace en termes de précision, pour la classification de l'occupation et l'utilisation des terres dans la zone côtière étudiée. Les résultats de cette étude ont révélé même si les deux algorithmes soient statistiquement significatifs, les évaluations de précision ont montré que le classificateur SVM était supérieur. L'analyse des résultats de combinaison de quelques indices spectraux avec l'algorithme SVM (par exemple avec l'indice MNDWI) a montré une valeur de précision OA supérieure à 92 %. Ainsi, l'approche proposée peut être mise en œuvre avec succès pour la cartographie de l'occupation et l'utilisation des terres des plaines urbaines côtières.

II.3.3. Algorithmes de classification

L'utilisation de modèles d'apprentissage automatique est devenue une pratique courante intégrée à la recherche en télédétection ces dernières années en raison de leur robustesse et de

leur capacité à classer l'occupation du sol (Gauci et *al.*, 2018; Rogan et *al.*, 2008). Les forêts aléatoires (Random Forest : RF), machines à vecteurs de support (Support Vector Machine : SVM), analyse discriminante linéaire, vraisemblance maximale et réseaux de neurones sont les classificateurs les plus souvent exploités pour la classification de l'imagerie satellitaire. Néanmoins, parmi ceux-ci, les algorithmes les plus populaires sont RF (Breiman, 2001) et SVM (Cortes et Vapnik, 1995), sont largement utilisés pour la modélisation de l'occupation du sol. En ce sens, plusieurs études ont montré que ces algorithmes surpassent systématiquement de nombreux autres classificateurs couramment utilisés (Adugna et *al.*, 2022; Feizizadeh et *al.* 2021; Pelletier et *al.* 2016), et sont adaptés à de nombreux scénarios dans différentes applications de classification.

Ces algorithmes d'apprentissage automatique sont des techniques flexibles et puissantes qui peuvent être mises en œuvre sur une grande variété de types et de combinaisons de capteurs satellitaires sur différentes échelles.

II.3.3.1. Forêts aléatoires

RF est une méthode d'apprentissage d'ensemble bien connue qui combine des K-trees binaires de CART (*Classification And Regression Trees*). C'est un puissant algorithme d'apprentissage automatique doté d'excellentes capacités de cartographie d'occupation du sol en utilisant différentes données sources (Liu et *al.* 2019b). RF est un modèle non paramétrique qui crée plusieurs arbres de décision, chaque arbre étant construit en assignant la classe la plus populaire aux images d'entrée.

Les arbres de décision sont construits en sélectionnant de manière aléatoire un sous-ensemble des variables d'entrée à chaque nœud. Ce nombre de variables utilisé pour diviser le nœud RF est la racine carrée du nombre de variables d'entrée (Liaw et Wiener, 2002). La limitation du nombre de variables utilisé pour chaque division permet de simplifier la complexité de calcul de l'algorithme et la corrélation entre les arbres.

Le processus de division se répète afin de réduire les corrélations entre les arbres et par conséquent, les résultats de la classification sont moins variables et plus fiables. La même opération est répétée pour chaque sous-ensemble jusqu'à ce que le nœud contienne des échantillons très similaires ou jusqu'à ce que la division n'ajoute aucune valeur à la prédiction. En conséquence, la construction de l'arbre peut s'arrêter lorsque la profondeur maximale (*max_depth*) est atteinte, ou lorsque le nombre d'échantillons au niveau du nœud est inférieur à un seuil de (*min_samples*). Au cours du processus de décision, chaque arbre classe les

données d'entrée, ensuite, le RF produit l'étiquette de la classe qui a reçu la majorité des votes (Pelletier et al., 2016).

Dans la classification de l'occupation du sol, le classificateur RF s'est révélé cohérent et relativement efficace, nécessitant peu de paramètres imposés par l'utilisateur et produisant un OA souvent uniforme ou meilleur que d'autres algorithmes (par exemple., arbres de décision conventionnels, *Maximum Likelihood*) (Lawrence, Wood, Sheley 2006). Pour l'entraînement du classificateur RF, deux paramètres importants doivent être assignés : le nombre maximum d'arbres (*Ntree*), et le nombre de caractéristiques doit être sélectionné pour chaque arbre (*Mtry*). Ensemble, ces deux paramètres ont une incidence élevée sur le rendement en matière de classification (Belgiu et Drăguț, 2016 ; Thanh Noi et Kappas, 2017). Dans la littérature, et au sujet de la modélisation de l'occupation du sol, le classificateur RF a été utilisé avec succès dans nombreuses études récentes : (Adugna et al., 2022 ; Alonso et al., 2021; Feizizadeh et al., 2021; Pelletier et al., 2016 ; Shetty et al., 2021; Sheykhmousa et al., 2020; Thanh Noi et Kappas, 2017).

II.3.3.2. Support Vector machine

La SVM est un algorithme non paramétrique pour les analyses d'images de classification et de régression (Liu et al., 2019a). Il est souvent utilisé dans les tâches de cartographie de l'occupation du sol, car il s'agit d'un classificateur discriminant qui minimise l'inexactitude des images en identifiant des solutions dans un hyperplan qui transforme les données en classes prédéfinies (figure II.6). Dans les cas où les caractéristiques des données sont indissociables, la SVM dispose d'une fonction noyau qui projette les données dans des fonctions d'ordre supérieur (Wang et al., 2016). Plusieurs fonctionnalités du noyau sont utilisées dans le modèle SVM : la fonction de base radiale gaussienne (RBF), en plus des fonctions polynomiales, linéaires et sigmoïdes.

En général, la fonction RBF est couramment appliquée pour la classification SVM. Généralement, dans les études de classification de l'occupation du sol, le noyau de la fonction de base radiale (RBF) du classificateur SVM est couramment utilisé et montre une bonne performance (Knorn et al., 2009 ; Shi et Yang, 2012). Les paramètres C et γ sont les deux paramètres fondamentaux contrôlant la performance de SVM (Foody, 2002a ; Huang et al., 2002). En effet, le paramètre C est utilisé pour contrôler l'ampleur des pénalités pour régulariser un ensemble de données d'apprentissage mal classées et joue un rôle important dans l'atteinte de l'exactitude et/ou de la généralisation de l'algorithme (Adugna et al., 2022).

Par ailleurs, le paramètre γ contrôle la largeur de noyau, ainsi, dans la classification SVM basée sur le noyau RBF, l'effet de γ est similaire à C parce que si une valeur élevée est attribuée, le modèle est trop ajusté et la généralisation n'est pas bonne (Foody *et Mathur*, 2004).




Figure II. 6. Exemple d'un SVM (adapté de (Burges, 1998)).

II.3.4. Méthode d'apprentissage automatique profonde le Réseau Neurones à convolution (Convolutional Neural Networks: CNN) et OBIA

Malgré le succès de l'OBIA dans le traitement précis de l'occupation et l'utilisation du sol, cette méthode reste relativement limitée en raison des incertitudes de classification associées aux objets irréguliers acquis via le processus de segmentation (Ma *et al.*, 2020). De plus, la précision de l'OBIA peut être compromise dans une grande variété de types de l'occupation et l'utilisation du sol, en particulier, dans les zones urbaines (Timilsina *et al.*, 2019), entraînant une mauvaise extraction des caractéristiques.

En outre, l'OBIA basée sur des classificateurs de Machine Learning utilisant les caractéristiques conçues, ou un classificateur binaire, ne considère généralement pas l'extraction de caractéristiques de niveau profond (Wang *et al.*, 2018). Par conséquent, les modèles d'apprentissage en profondeur (Deep Learning), un sous-ensemble de techniques d'apprentissage automatique, ont été développés pour résoudre divers problèmes de traitement d'images (LeCun *et al.*, 2015), et leur intégration dans la télédétection a apporté une grande adaptabilité dans la représentation des objets, avec des niveaux élevés d'extraction des caractéristiques à partir des données d'imagerie. La classification basée sur les modèles de Deep Learning peut permettre d'augmenter la quantité d'informations extraites, améliorant ainsi les

résultats de classification pour certaines tâches de l'occupation du sol (Li et *al.*, 2019 ; Sefrin et *al.*, 2020). Parmi les algorithmes du Deep Learning, figurent les réseaux de neurones convolutifs (CNN: Convolutional neural Networks), qui sont beaucoup appliquée en télédétection pour la classification de l'occupation du sol.

II.3.4.1. Utilisation de l'algorithme CNN pour la modélisation de l'occupation du sol

Les CNNs sont utilisés dans de nombreuses tâches de classification de l'occupation du sol. Ces modèles utilisent des noyaux de convolution empilés pour apprendre l'information spectrale et spatiale, améliorant ainsi l'identification des caractéristiques abstraites de haut niveau. Néanmoins, les méthodes conventionnelles CNN sont caractérisées par un grand nombre de couches, ce qui entraîne d'importants coûts de calcul (Pan et *al.*, 2020a).

En outre, les méthodes de classification CNN sont souvent exécutées au niveau des pixels; par conséquent, les caractéristiques extraites peuvent être confondues en raison de la distribution spatiale mixte des types de l'occupation de sol et du mélange spectral (Jin et *al.*, 2019a). Alternativement, les méthodes OBIA utilisent des ensembles multi-pixels homogènes pour classer les objets ; ainsi, il pourrait être optimal d'intégrer les modèles CNN avec OBIA lors de la classification des objets segmentés. Cette méthode avancée a été testée dans diverses applications de cartographie de l'occupation du sol (Zaabar et *al.*, 2022; Zaabar et *al.*, 2021), de la surveillance des changements côtiers (Xie et Niculescu, 2021) et de la classification des terres agricoles (Belgiu et Csillik, 2018). Aussi, il a été démontré que cette méthode intégrée est capable d'extraire des caractéristiques d'image de haut niveau, de discriminer et définir efficacement les limites entre différentes classes de l'occupation du sol et d'améliorer la précision de la classification (Maggiori et *al.* 2017; Mahdianpari et *al.* 2018; Sefrin et *al.*, 2020).

II.3.4.2. Architecture de la méthode CNN

Les modèles CNN développés pour la classification des images sont inspirés de l'architecture des réseaux de neurones biologiques multicouches, permettant de construire des caractéristiques sémantiques de haut niveau à partir de caractéristiques spécifiques de bas niveau (Ghorbanzadeh et *al.*, 2021; Jin et *al.*, 2019).

Une architecture CNN typique contient des couches continues, couches convolutionnelles (Convolutional Layers), couches de regroupement (*Pooling Layers*), couches entièrement connectées (*Fully Connected Layers*) et des couches de sortie interconnectées utilisant des opérations non linéaires (Wang et *al.*, 2018). Deux caractéristiques importantes sont prises en compte dans toute architecture CNN : la connectivité locale conçue pour simplifier CNN en

limitant le nombre de neurones connectés, et des poids partagés responsables de la réduction et de la simplification des paramètres du modèle en considérant les mêmes poids reliés entre différents neurones dans une couche donnée (Pan et *al.*, 2020). De même, grâce à des couches convolutives, un modèle CNN peut extraire des caractéristiques basées sur de multiples opérations convolutives de l'image d'entrée, transformant les champs récepteurs locaux des régions connectées des données d'entrée en pixels de la couche suivante. En outre,

Les couches (*Pooling Layers*) sont également importantes dans les modèles CNN. Cela réduit la dimensionnalité des cartes d'entités en fusionnant des entités similaires en une seule (Tang et *al.*, 2020; Zhang et *al.*, 2018).

Les couches (*Pooling Layers*) peuvent être appliquées sous deux formes : couches maximales (*Max Pooling Layers*) ou couches minimales (*Average Pooling Layers*). En général, ce sont les couches les plus couramment appliquées dans les CNN. De plus Il est à noter que, chaque couche CNN est générée par de petits patches d'échantillons d'une certaine taille qui générés depuis l'image d'entrée et extraient diverses caractéristiques.

II.4. Télédétection et évaluation des changements de l'occupation du sol

Les changements de l'occupation et l'utilisation des terres sont considérés comme un enjeu environnemental critique ayant des répercussions mondiales sur la gestion de l'environnement et le développement durable (Guan et *al.*, 2011; Veldkamp et Lambin, 2001).

En effet, l'occupation du sol à travers le monde subit encore des changements majeurs dus à des facteurs naturels et anthropiques, notamment les changements climatiques, l'urbanisation rapide principalement dans les zones critiques, la croissance démographique qui nécessite le développement de l'agglomération urbaine, et l'agrandissement subséquent des constructions. Parallèlement, des événements extrêmes, tels que la dégradation du paysage et les crues éclair affectant les processus hydrologiques dus au changement climatique modifient considérablement la dynamique de l'occupation du sol (Farjad et *al.*, 2017; Garg et *al.*, 2019). Dans cette optique, l'acquisition et la détection rapides de données sur les changements de l'occupation du sol constituent un élément essentiel de la surveillance environnementale, de la planification urbaine et du développement durable. La compréhension de la dynamique et des changements de l'occupation du sol, ainsi que de ses interactions avec les activités humaines et les risques naturels est essentielle pour améliorer la gestion des territoires et la prise de décisions (Zaabar et *al.*, 2021).

Additivement, l'information sur les changements et l'évolution de l'occupation du sol est considérée comme une base de données indispensable pour plusieurs considérations environnementales, comme la gestion des ressources en eau et l'évaluation des risques naturels (Bello *et Aina*, 2014 ; Psomiadis *et al.*, 2019 ; Yin *et al.*, 2017; Zope *et al.*, 2017).

Au cours des dernières décennies, la télédétection est devenue un moyen puissant de suivre les changements de l'occupation du sol à l'aide de méthodes Machine Learning de classification des images satellitaires (Chen *et al.*, 2019; Hansen *et al.*, 2000; Mas, 1999 ; Myint *et al.*, 2011; Singh, 1989).

En raison des limites de la méthode basée sur les pixels, la méthode OBIA a été largement utilisée pour détecter les changements de l'occupation du sol. Selon des études précédentes, cette méthode a permis de classer avec précision les changements de l'occupation du sol à l'aide d'images à haute et très haute résolution (Alqurashi *et al.*, 2016 ; Halmy *et al.*, 2015). En 2016, (Alqurashi *et al.*, 2016) a fourni des cartes de l'occupation du sol utilisant des images de Landsat de 1985, 1990, 2000, 2007 et 2014 pour cinq villes d'Arabie saoudite. L'objectif de l'étude consiste en l'évaluation de la croissance du milieu urbaine dans ces villes. La classification de l'occupation du sol a été réalisée en utilisant une approche OBIA. Les images classifiées ont également été utilisées pour prédire les changements de l'occupation du sol et la croissance des zones urbaines en 2024 et 2034 à l'aide de modèles précis. Les changements ont été évalués à l'aide des probabilités de transition. La fonction de sélection de l'information basée sur Extreme Gradient Boosting (XGBoost) et l'algorithme RF ont été exploités pour effectuer la classification OBIA. Les résultats de classification ont montré des valeurs plus élevées de la précision globale (OA), jusqu'à 90 %, ce qui a été très bénéfique pour évaluer les dynamiques de l'occupation du sol.

(How Jin Aik *et al.*, 2020) ont appliqué méthode OBIA pour classer et d'évaluer les changements de l'occupation du sol dans les Cameron Highlands en Malaisie en exploitant les avantages et les caractéristiques de la méthode OBIA, telles que, texture, forme, position et ainsi que les différentes combinaisons de bandes spectrales. Les auteurs ont utilisé des images de séries chronologiques Landsat de 2009 à 2019 comme données de télédétection.

De même, (Putri *et Wicaksono*, 2021) a cartographié les changements de l'occupation du sol dans la zone centrale des dunes de sable situées en Indonésie à l'aide d'images aériennes prises entre 2015 et 2020. L'algorithme du voisin le plus proche a été utilisé pour la classification de l'occupation du sol après un processus de segmentation. L'analyse des changements dans

l'utilisation des terres a été effectuée en comparant les résultats de la classification de l'utilisation des terres de 2015 et de 2020.

II.5. Évaluation de la précision de la classification de l'occupation du sol

L'évaluation de la précision de la classification de la couverture terrestre vise à valider les résultats et à confirmer la stabilité des classificateurs utilisés pour la classification. En effet, plusieurs méthodes d'évaluation de la précision sont discutées dans la littérature sur la télédétection. Cependant, le calcul statistique de la matrice dite de "confusion" est la méthode la plus couramment utilisée en télédétection. L'intérêt de la matrice de confusion a été souligné par Congalton (1991). Une matrice de confusion est un tableau carré de nombres distribués en lignes et en colonnes qui représentent le nombre d'unités d'échantillonnage affectées à une catégorie particulière par rapport à la catégorie réelle validée par des informations de vérité terrain ou un ensemble de données de référence. Essentiellement, la matrice de confusion permet une analyse à la fois descriptive et analytique (Smits et al., 1999).

Par ailleurs, des indices de précision sont calculés à partir de la matrice de confusion pour évaluer la précision globale et précision par classe de la classification. Ces indicateurs sont :

- La précision globale ou *Overall Accuracy* (OA) : indique le pourcentage de classements corrects par rapport au nombre total de régions classées. Il est basé sur la somme des éléments diagonaux de la matrice de confusion normalisée par le nombre total de régions N.

$$OA = \frac{1}{N} \sum_{i=1}^c n(i, i) \quad (\text{II.1})$$

Où C le nombre de classes et n les entrées de la matrice de confusion.

- L'indice Kappa (K) (Cohen, 1960) est un indice global de précision de classification différant de l'OA. Il considère la proportion P_h de classes correctes classées aléatoirement. Il s'exprime comme suit :

$$k = \frac{OA - P_h}{1 - P_h} \quad (\text{II.2})$$

Avec :

$$P_h = \frac{1}{N^2} \sum_{i=1}^c n(., i), (i, .) \quad (\text{II.3})$$

Où $n(., i)$ et $n(i, .)$ représentent la somme de i colonnes et i lignes, respectivement. Plus Kappa est proche de 1, plus la concordance entre la vérité terrain et la classification est

forte. Ainsi, un kappa de 0,75 signifie que 75 % des classifications correctes ne sont pas dues au Hazard.

- La précision du producteur ou *Producer's accuracy* (PA) est la probabilité qu'une région appartenant à une classe de vérité terrain particulière soit classée correctement. Contrairement à OA, il s'agit d'une métrique de précision par classe. Pour la j-ème classe, il est obtenu par :

$$PA_j = \frac{n(j, j)}{\sum_{i=1}^c n(i, j)} \quad (\text{II.4})$$

Et donc, le PA représente donc le nombre de régions dans la j-ème classe correctement classée divisé par la somme des j-ème colonnes de la matrice de confusion. Cette mesure correspond à une sorte d'indice de confiance que les producteurs de classification peuvent attribuer à leurs procédures de classification.

- La précision de l'utilisateur ou *User's accuracy* (UA) est la probabilité qu'une région classée dans une classe particulière appartienne réellement à cette classe. Pour une i-ème classe, il est obtenu par :

$$UA = \frac{n(i, i)}{\sum_{j=1}^c n(i, j)} \quad (\text{II.5})$$

Il est donc égal au nombre de régions correctement classées de la i-ème classe divisé par la somme de la i-ème ligne de la matrice de confusion. Cette mesure correspond à une sorte d'indice de confiance que les utilisateurs de la carte créée peuvent donner à cette carte.

Conclusion

Ce premier chapitre, d'une part, a fourni un état de l'art sur l'apport de la télédétection et des capteurs satellitaires à différentes résolutions spatiales, spectrales et temporelles dans le contexte de la classification de l'occupation du sol. D'autre part, une synthèse des méthodes d'analyse d'images et de classification les courantes de l'occupation du sol ont été établie. Plusieurs conclusions peuvent être tirées de cette revue de la littérature :

- Divers capteurs de télédétection sont disponibles aujourd'hui en fonctionnement pour émettre le signal électromagnétique sur pratiquement tout le globe terrestre. De plus, les capteurs de télédétection avec des caractéristiques spectrales et des résolutions spatiales (moyenne, haute HRS et très haute THRS) ont un grand potentiel pour étudier et analyser l'évolution spatio-temporelle de l'occupation du sol et la surveillance de l'environnement.
- La plupart des études de classification de l'occupation du sol appliquées à l'imagerie haute et THRS résolution spatiale ont recours à des approches de *Machine Learning*, soit des méthodes traditionnelles (orientées pixels) soit des méthodes basées sur des objets (OBIA). Les modèles d'apprentissage en profondeur sont récemment apparus comme des outils puissants pour aider à résoudre une variété de problèmes de traitement d'images et de classification de l'occupation du sol. Parmi ces modèles figure les CNNs.
- Dans la littérature sur la télédétection, la synergie des données satellitaires optiques/radar pour la modélisation de l'occupation du sol a été démontrée avec succès pour améliorer la précision des informations et exploiter les propriétés spectrales de l'optique et structurelles du radar.
- L'utilisation de classificateurs Machine Learning est devenue une méthode populaire intégrée dans la recherche en télédétection. RF et SVM font preuve de robustesse et d'efficacité pour une modélisation d'occupation du sol de haute qualité par rapport à d'autres classificateurs.
- Très récemment, la combinaison de modèles de Deep Learning (notamment les CNNs) avec des approches de classification basées sur des concepts d'objets et la segmentation a montré un grand potentiel pour la classification de la couverture terrestre et l'extraction d'informations de haut niveau.

Au vu de ces quelques observations, la modélisation de l'occupation du sol à l'aide des méthodes de Machine Learning et Deep Learning utilisant des classificateurs efficaces constitue une solution intéressante à la fois en termes d'analyse de l'imagerie satellitaire de différentes caractéristiques spectrales et spatiales de HRS et THRS, mais aussi à extraire des informations sur l'occupation du sol utiles pour l'étude des inondations, qui reste un objectif principal de cette thèse. Cette synthèse bibliographique confirme l'intérêt de tester ces méthodes et d'évaluer les performances dans un contexte de classification d'images optiques à haute et très haute résolution. De même, en développant une approche synergique, cela va nous permettre également de tester les méthodes sur des données combinées optique et radar.

Le chapitre suivant les sites d'études choisis pour l'élaboration des méthodologies proposées ainsi les données nécessaires mises en œuvre.

**PARTIE II : SITES
D'ETUDES ET DONNEES**

CHAPITRE III
SITES D'ETUDE ET DONNEES MISES EN
OUVRE

CHAPITRE III : SITES D'ETUDE ET BASES DE DONNEES MISES EN ŒUVRE

Introduction

Le chapitre suivant est divisé en trois parties principales : la première s'articule autour de la description du cadre général des sites d'études. Le premier site se trouve dans la région côtière de la wilaya d'Ain Témouchent distant de 365 km de la capital Alger et le second est situé au niveau de la ville côtière de Ténès une province de la wilaya de Chlef, située à 220 Km à l'Ouest d'Alger.

Le choix des deux sites d'étude est dû aux antécédents inondations graves produits au niveau des deux zones d'études, identifiées et classées comme étant des zones urbaines à haut risque d'inondation, selon la stratégie du secteur des ressources en eau dont la mission est d'établir les plans de prévention des risques d'inondation, conformément au cadre règlementaire défini par la Loi n°04-20 du 25 décembre 2004 relative à la prévention des risques majeurs et à la gestion des catastrophes dans le cadre du développement durable.

La seconde partie est consacrée à la base de données construite lors des travaux de thèse. Elle comporte principalement des données satellitaires optiques et radar avec différentes résolutions spatiales acquises sur deux sites d'étude. Ces données satellitaires vont être exploitées pour établir les méthodologies dédiées à la modélisation de l'occupation du sol. Ces données satellitaires seront utilisées pour développer la méthodologie de modélisation de l'occupation du sol.

L'imagerie satellitaire est complétée par le recours aux Modèles Numériques de Terrain (MNT) afin d'établir un second volet de notre méthodologie dédié à la modélisation hydraulique et l'évaluation du risque inondation.

La troisième partie s'intéresse à la description des différentes caractéristiques géographiques, physiographique, climatiques et hydrologiques du bassin versant de l'Oued Allala traversant la ville de Ténès. Ce bassin versant a connu de nombreuses crues extrêmes au fil des années. Par conséquent, ce sera le site à expérimenter pour appliquer la méthodologie de modélisation des risques d'inondations de cette thèse. Cette partie décrit également les données hydrométriques qui seront utilisés dans l'étude des crues et la construction de l'hydrogramme des crues et la détermination des périodes de retour.

III.1. Sites d'études : villes côtières Ain Témouchent et Ténès

III.1.1. Site d'étude Ain Témouchent

Le premier site d'étude est celui de la zone côtière de Ain Témouchent, situé dans le nord-ouest de l'Algérie, au croisement entre trois grandes villes : Oran, Sidi Bel Abbès, et Tlemcen (Figure. III.1). La zone comprend la région côtière méditerranéenne d'Ain Témouchent et le centre-ville ; en outre, il intègre le bassin versant de Sennane, qui traverse l'agglomération urbaine (superficie totale de 84 km²) comme son point de contrôle en aval de la ville.

La ville est entourée de zones montagneuses avec une altitude moyenne de près 500 m. Influencée par le climat méditerranéen, la région de l'Ain Témouchent est caractérisée par un été chaud et un hiver tempéré. En outre, les vents du nord-ouest et du sud-est apportent peu d'humidité à la région, car ils traversent les reliefs marocains du sud.

La zone d'étude est caractérisée par une occupation du sol hétérogène en raison de son confinement dans une vallée étroite, tout en étant entourée de vignobles et de parcelles agricoles d'agriculture disposés sur un sol basaltique à forte fertilité. Les catégories de l'occupation du sol les plus dominantes dans la région sont le bâti, les forêts et les terres agricoles, les deux dernières étant situées principalement dans la région rurale.

La région se caractérise par une production agricole et une activité viticole plus élevées, représentant 25% de la production nationale (Derfouf, 2015). Selon la situation géographique, ces activités agricoles impliquent non seulement le secteur des services, mais aussi une croissance démographique importante. Le couvert végétal est constitué de masses forestières, remplacées à certains endroits par des fermes de montagne. Les rues urbaines sont caractérisées par l'aménagement et l'architecture française.

Aujourd'hui, la ville poursuit un développement urbain à grande échelle au détriment des terres agricoles et des vignobles. La ville d'Ain Témouchent se caractérise également par une croissance démographique rapide. Selon le bureau national des statistiques, la population de la ville était estimée à environ 97 812 habitants en 2014, avec un taux de croissance de +1,38 %/an de 1987 à 1998 et de +2,52 %/an de 1998 à 2008. Par conséquent, la diversité des catégories de l'occupation du sol dans la zone d'étude permet d'évaluer la faisabilité de la méthodologie d'extraction d'objets de l'occupation du sol proposée. La ville d'Ain Témouchent est exposée au risque d'inondation (Tableau III.1), ce qui nécessite une actualisation des données de l'occupation du sol et une analyse approfondie des zones sujettes aux inondations.

Tableau III.1. Inondations historiques dans la région Ain Témouchent (AGIRE, 2014).

Région	Ain Témouchent centre	Région Terga et plage	Oued Sennane	Oued El-Mallah
Principaux évènements	-2000-2003 -2011-2018	-2000 -2003 - 2011 -2018- 2019	-2003-2007- 2008 - 2011- 2013- -2017-2018- 2019	-2000 - 2003 -2011- 2018 - 2019
Fréquence des débordements	1 fois /5 ans	1 fois /5 ans	1 fois /5 ans	1 fois /5 ans
Typologie des inondation	Ruissellement pluvial urbain	Ruissellement pluvial urbain	-débordement naturel des lits de l'Oued -débordement de réseau pluvial	Débordement des lits de l'Oued débordement de réseau pluvial
Cause	Pluies généralisées	Pluies généralisées	Fortes pluies	Fortes pluies
Durée de Submersion (jour)	< 1 jour	< 1 jour	< 1 jour	< 1 jour
Dommages causés	Dégâts matériels	Dégâts Humains Dégâts matériels	Dégâts Humains Dégâts matériels	Dégâts Humains et Matériels




Figure III.1. Localisation de site d'étude - Ain Témouchent, ouest algérien.

III.1.2. Site d'étude Ténès

La zone d'étude se situe au nord de l'Algérie, à mi-distance entre Alger et Oran le long de la côte méditerranéenne (Figure III.2). La région est influencée par le climat méditerranéen et se caractérise par un climat chaud et tempéré avec des précipitations importantes pendant les mois d'hiver.

La ville, d'une part, peut jouer un rôle régional important en raison de sa situation géographique et de ses équipements actuels et futurs. D'ici 2029, selon le rapport d'investigation de l'Agence Nationale de Gestion Intégrée des Ressources en Eau (AGIRE), la population devrait être de 50 000 habitants. Les aires urbaines mobilisées pour répondre aux besoins de cette population sont de plus en plus en évolution et elles se mobilisent autour de la ville urbaine de Ténès pour répondre aux besoins de cette population.

Ces dernières années (novembre 2001, novembre 2011, novembre 2012), la ville a connu des inondations dans sa zone basse (Tableau III.2). Des maisons et des infrastructures ont été endommagées, et parfois des vies ont été perdues. La zone la plus critique est celle correspondant au secteur urbain de la région. Cela comprend de petites plaines et des collines adjacentes autour du confluent des rivières Oued Allala et Boufessousa.

Ces inondations étaient dues en grande partie à l'importance des bassins versants et des massifs forestiers, aggravant les feux de forêts et rendant difficile le transport des sédiments et de la végétation.

Le ruissellement de ce canal de drainage traverse une plaine qui se rétrécit à environ 900 mètres avant d'être déversé dans la mer. En plus de cela, l'eau de mer monte à l'embouchure de l'oued, empêchant les eaux de crue de s'écouler correctement.

Tableau III.2. Inondations historiques dans les région Chlef et Ténès (AGIRE, 2014).

Région	Oued Allala	Oued Boufessoussa	Oued Tifiles	Ruissellement pluvial urbain
Principaux évènements	1985, 1986, 2000, 2002, 2006, 2007, 2008, 2010, 2011, 2012, 2013, 2016, 2017			
Fréquence des débordements	1 fois / 1 à 2 ans	1 fois / 1 à 2 ans	1 fois / 1 à 2 ans	1 fois / 1 à 2 ans
Typologie des inondation	crues rapides et ruissèlement pluvial	crue éclair	- crue éclair) débordement de réseau pluvial	Débordement des lits de l'Oued débordement de réseau pluvial
Cause	Pluies généralisées Débordement de cours d'eau	Pluies généralisées Débordement de cours d'eau	Fortes pluies Débordement de cours d'eau	Fortes pluies
Durée de Submersion (jour)	< 1 jour	< 1 jour	< 1 jour	< 1 jour
Dommages causés	Dégâts Matériels et humains	Dégâts Humains Dégâts matériels	Dégâts Humains Dégâts matériels	Dégâts Humains et Matériels

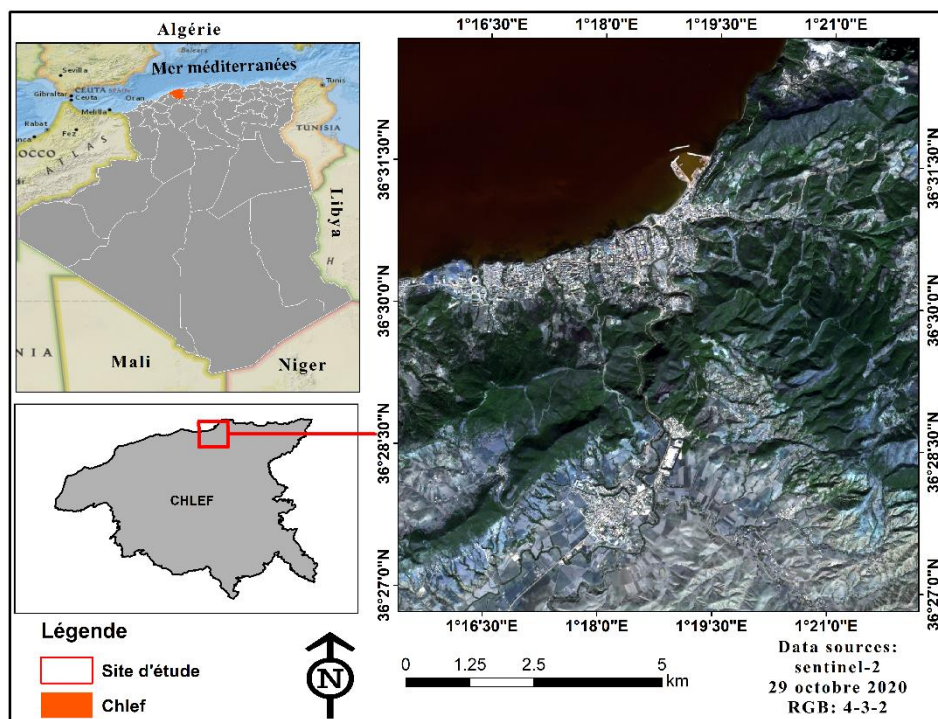


Figure III.2. Localisation de site d'étude - Ténès, wilaya de Chlef, Ouest Algérien.

III.2. Données satellitaires

L'objectif principal de cette thèse repose sur l'exploitation du potentiel des capteurs de télédétection avec une résolution spatiale élevée et des temps de retour fréquents pour les études des plaines inondables.

Cette section présente deux types de données satellitaires utilisées dans deux phases différentes de la méthodologie appliquée. Tout d'abord, des images satellitaires sont acquises à différentes résolutions spatiales issues de différents capteurs, à savoir Sentinel-1, Sentinel-2, Landsat et Pléiades. Ces différents types d'imagerie sont utilisés pour la modélisation de l'occupation du sol.

Ensuite, des données topographiques sont également acquises. Il s'agit principalement d'un MNT à 12,5 m de résolution et une image Pléiades tri-stéréoscopique utilisée pour extraire un modèle numérique du surface (MNS) à très THRS. Ces données topographiques dans la partie modélisation hydraulique des inondations.

III.2.1. Images Sentinel-2

Un ensemble d'images Sentinel-2 a été acquis dans notre thèse le long de deux sites d'études. Les images sentinel-2 ont été exploitées principalement pour :

- Une approche synergique pour la cartographie de l'occupation du sol avec les capteurs radar (Sentinel-1) sur le site Ain Témouchent.
- Approche comparative de cartographie de l'occupation avec les Pléiades site Ain Témouchent acquises à la même date d'acquisition des images Pléiades.
- Une approche de cartographie de l'occupation du sol sur le site de Ténès.
- Une approche de cartographie de l'occupation du sol et la détection des changements le long du bassin versant Oued Allala.

Toutes les images Sentinel-2 ont été dérivées librement via le Sentinel-Hub (<https://scihub.copernicus.eu/>). Ces images possèdent 13 bandes spectrales et une résolution spatiale élevée. Par conséquent, cette résolution spatiale, spectrale et temporelle élevée des satellites Sentinel-2 est appropriée pour les programmes de surveillance de l'occupation du sol. Compte tenu de sa fréquence élevée de revisite (10 jours pour un seul satellite Sentinel-2 et 5 jours pour la constellation combinée).

Le tableau III.3 illustre toutes les images Sentinel-2 avec les dates d'acquisition, utilisées dans ce travail. Le tableau III.4 fournit des propriétés d'acquisition supplémentaires de l'imagerie Sentinel-2.

Tableau III. 3. Dates d'acquisitions et objectifs d'utilisation des images sentinel-2.

Type de données	Dates d'acquisition	Site d'étude	Problématique traitée
Sentinel-2 Orbites : 103 et 105	01 Janvier 2019	Ain	- Approche synergique avec les capteurs radar (Sentinel-1) pour la cartographie de l'occupation du sol.
	09 Mars 2019	Témouchent	
	21 Mars 2019		
	01 Mai 2019		
	08 Mai 2019		
	18 Juin 2019		
	19 Juillet 2019		
	24 Juillet 2019		
	12 Aout 2019		
	05 Septembre 2019		
	16 Septembre 2019		
	16 Novembre 2019		
		17 Octobre 2020	
	29 Octobre 2020	Ténès	- Approche méthodologique pour la modélisation de l'occupation du sol de la région Ténès.
	8 mars 2020	Ténès	- Approche de classification de l'occupation du sol pour la détection des changements bassin versant Allala sur le site de Ténès.

Tableau III.4. Caractéristiques spectrales des images Sentinel-2.

Type image	Bande	Longueur d'onde (nm)	Résolution spatiale (m)
Sentinel 2	2	492.4	10
	3	559.8	
	4	664.6	
	8	832.8	
	5	704.1	20
	6	740.5	
	7	782.8	
	8a	864.7	
	11	1613.7	
	12	2202.4	
	1	442.7	60
	9	945.1	
10	1373.5		

III.2.2. Image Sentinel-1

Pour les produits Sentinel 1, une série temporelle d'images de 12 dates couvrant l'année 2019 a été téléchargée. Le satellite Sentinel-1 a un capteur radar à Synthèse d'Ouverture (SAR) en bande C, dont la longueur d'onde est d'environ 5,5 cm. Les scènes d'image Sentinel-1 ont été acquises en format GRD (*Ground Range Detected*), en orbites 103 et 110 en mode d'acquisition IWS (*Interferometric Wide Swath*) avec une double polarisation VH (Verticale-Horizontale) et VV (Verticale-verticale). La résolution spatiale des produits Sentinel 1 est de 10 mètres. Le tableau III.5 fournit les informations relatives aux dates d'acquisition des images Sentinel-1, utilisées dans ce travail.

Tableau III.5. Dates d’acquisitions et objectifs d’utilisation des images sentinel-1.

Type de données	Dates d’acquisition	Site d’étude	Problématique traitée
Sentinel-1	26 Janvier 2019	Ain	Cartographie de l’occupation du sol-Ain Témouchent.
	05 Février 2019	Témouchent	
	02 Mars 2019		
	12 Mars 2019		
	17 Mars 2019		
	16 Avril 2019		
	10 Juillet 2019		
	30 Juillet 2019		
	14 Aout 2019		
	24 Aout 2019		
	08 Octobre 2019		
	13 Octobre 2019		

III.2.3. Images Pléiades

Deux ensembles de données Pléiades étaient nécessaires pour couvrir les sites d’étude dans ce travail. Le premier ensemble de données Pléiades couvrant le site d’Ain Témouchent (le centre-ville et la région côtière) et le deuxième couvrant le site d’étude de Ténès. L’imagerie Pléiades THRS est dérivée d’un satellite à double optique (Pléiades 1A) et (Pléiades 1 B) conçus pour l’observation de la Terre disponible sur commande (Figure III.3).




Figure III.3. Constellation des Pléiades 1A/1B et des SPOT 6/7.

Pour le site d'Ain Témouchent deux images Pléiades ont été acquises le 17 octobre 2020 à partir de la plateforme 1A pour couvrir la totalité de la zone étudiée. Un sous ensemble d'image Pléiades et Sentinel-2 est montré dans la Figure III.4. Sur le site de Ténès, une image de Pléiades couvrant le site et le bassin versant étudié a été acquise auprès de la Plateforme 1A le 10 octobre 2022, respectivement (Tableau III.6).

Tableau III. 6. Dates d'acquisition de objectifs d'utilisation des images Pléiades.

Type de données	Dates d'acquisition	Site d'étude	Problématique traitée
Pléiades	17 octobre 2020	Ain Témouchent	Cartographie de l'occupation du sol-Ain Témouchent.
Pléiades tri-stéréopique	10 octobre 2022	Ténès	- Cartographie de l'occupation du sol-Ténès et bassin versant oued Allala - Extraction MNT pour la modélisation hydraulique

Les images Pléiades comprenaient des images panchromatiques et quatre canaux multispectraux (rouge, vert, bleu et proche infrarouge – NIR), à une résolution spatiale de 2 m. Les propriétés d'acquisition de Pléiades sont présentées dans le Tableau III.7. Toutes les images ont été obtenues dans de bonnes conditions nuageuses (0 %).

Tableau III.7. Caractéristiques spectrales et résolution spatiales des images Pléiades.

Caractéristiques géométriques	Pléiades	Pléiades
	17 octobre 2020	10 octobre 2022
Angle d'incidence	9.18° - 9.75°	12.8°-12.9°
Élévation solaire	43°	69°

En plus, Ces images ont été fournies orthorectifiées avec les corrections géométriques d'usage. Les métadonnées relatives à la géométrie d'acquisition (angle d'incidence et élévation solaire) des images décrites dans le Tableau III.8.

Tableau III.8. Métadonnées relatives à la géométrie d'acquisition (angle d'incidence et élévation solaire) des images Pléiades.

Type de données	Bande	longueur d'onde (nm)	Resolution Spatiale (m)
Pléiades 1A	Bande 0 (blue)	430–550 nm	2
	Bande 1 (green)	490–610 nm	
	Bande 2 (red)	600–720 nm	
	Bande 3 (NIR)	750–950 nm	




Figure III.4. Composition colorée (RGB) d'un sous-ensemble couvrant la partie sud-ouest du centre-ville de Ain Témouchent : A droite : Image Pléiades, à gauche : image Sentinel-2.

III.2.4. Image Landsat

Le satellite Landsat-5 TM a été lancé en mars 1984 par la *National Aeronautics and Space Administration* (NASA) et mis hors service en janvier 2013, il est une ressource inestimable pour l'analyse temporelle et spatiale de la végétation, de l'eau, de la neige et des zones de construction. Il s'agit d'une ressource précieuse pour l'analyse temporelle et spatiale de la végétation, de l'eau, des zones urbaines et en particulier, l'évolution des changements de l'occupation du sol. Le programme Landsat fournit le plus long enregistrement continu au monde de la surface de la Terre. Depuis le lancement de ses huit satellites, une grande quantité

d'images Landsat de séries temporelles à long terme ont été collectées, contribuant à une compréhension de la Terre de diverses manières.

Dans ce travail, deux images ont été acquises à partir de capteur Landsat-5 TM pour classifier et détecter les changements de l'occupation du sol. Les deux images Landsat-5 TM ont une résolution spatiale de 30 m, acquises le 10 avril 1999 et le 8 mai 2009, accessibles gratuitement sur site USGS (<https://glovis.usgs.gov>). Le but d'exploiter deux images à 10 ans d'intervalle est d'évaluer le changement de l'occupation du sol dans le bassin versant choisi pour l'étude. Les images sont acquises sous une couverture nuageuse très faible (<3%).

Les données brutes sont des données corrigées du terrain de niveau 1 (L1T), corrigées radiométriquement, co-enregistrées avec des projections cartographiques, corrigées des changements de terrain et produisant des images numériques orthorectifiées standard. Les propriétés spectrales spécifiques de l'imagerie Landsat-5 TM, ainsi que la dates d'acquisitions et les objectifs d'utilisation, sont présentées dans les tableaux III.9 et III.10, respectivement.

Tableau III.9. Propriétés spectrales des bandes des images Landsat-5 TM.

Type de données	Bande	Longueur d'onde (nm)	Résolution Spatiale (m)
Landsat	Bande 1 (Blue)	0.45 - 0.52	30
	Bande 2 (Green)	0.52 - 0.60	
	Bande 3 (Red)	0.63 - 0.69	
	Bande 4 (NIR)	0.76 - 0.90	
	Bande 5 (SWIR-1)	1.55 - 1.75	
	Bande 7 (SWIR-2)	2.08 - 2.35	

Tableau III.10. Dates d'acquisition et objectifs d'utilisation des images Landsat-5 TM.

Type de données	Dates d'acquisition	Site d'étude	Problématique traitée
Landsat-5TM	10 Avril 1999 8 Mai 2009	Ténès	Classification et évaluation des changements de l'occupation du sol du bassin versant Oued Allala

III.2.5. Données topographiques

Deux différents types de données topographiques à différentes résolutions sont exploités dans ce travail. L'objectif principal de l'utilisation des données topographiques est dans la partie de modélisation hydraulique en tant que données d'entrée pour la simulation du modèle hydraulique.

III.2.5.1. MNT 12,5 m

Le premier type de données topographiques est celui constitué par le MNT obtenu à partir du ALOS PALSAR (*Digital Elevation Model*) à 12,5x12,5 m de résolution, disponible sur la plateforme (<https://vertex.daac.asf.alaska.edu/?#>) dérivée par le satellite Alaska satellite facility. En effet, le ALOS est un successeur des satellites JERS-1 (*Japanese Earth Resources Satellite-1*) et ADEOS (*ADvanced Earth Observing Satellite*). Ses principales missions comprennent la cartographie à l'échelle régionale, les observations de la terre pour la surveillance des ressources naturelles et des catastrophes naturelles et causées par l'homme.

Le satellite ALOS dispose de trois capteurs de télédétection, dont PALSAR (Phased Array type L-band Synthetic Aperture Radar) (Figure III.5). PALSAR est donc un capteur actif dans le domaine des micro-ondes destiné à l'observation de la surface terrestre jour/nuit par temps clair ou couvert nuageux. Dans ce travail, nous avons obtenu un MNT couvrant le bassin de l'Allala sélectionné pour la simulation du modèle hydraulique.




Figure III.5. Satellite ALOS avec ses différents instruments (y compris le capteur actif)

III.2.5.2. MNS tri-stéréo Pléiades

Avec sa constellation et ses deux satellites volant sur des orbites héliosynchrones avec une inclinaison de 98,2 ° et un décalage de 180° l'une de l'autre, le système Pléiades est le premier système de ce type capable d'acquérir au moins trois images quasi synchrones de la même région à des angles stéréo variant entre 6° et 28° (Figure III.6). Cette capacité stéréoscopique permet de créer des MNS précis et à THRS de surfaces topographiques complexes (Lacroix, Berthier, Maquerhua 2015). Dans ce but et pour simuler un modèle de crues hydrauliques à partir de données satellitaires à très haute résolution, deux images Pléiades tri-stéréoscopiques

ont été acquises le 16 et 21 Juin 2022, couvrant le bassin versant Allala. Ces images ont été traitées pour générer le MNS utilisés dans le modèle hydraulique




Figure III.6. Capacité tri-stéréoscopique de satellite Pléiades (Airbus, 2022).

III.3. Présentation de bassin versant Oued Allala (Ténès) et données hydrométriques utilisées pour la modélisation hydraulique

III.3.1. Présentation générale et caractéristiques du bassin versant : Oued Allala

Le bassin versant choisi pour établir la méthodologie de simulation hydraulique du risque d'inondation est celui d'Oued Allala. Ce bassin versant est situé dans le nord de l'Algérie sur la côte méditerranéenne. Il est localisé entre les latitudes 36.30° et 36.55° Nord, 1.05° et de longitude 1.45° Est, et situé au sud de la ville de Ténès.

Le bassin hydrographique couvre une superficie totale de 307 km^2 et une longueur de 35 km pour son principal talweg (Figure III.7). La zone est située entre l'altitude maximale et minimale, 1032 m et 44 m , respectivement, et comprend la ville de Ténès ; une ville touristique et portuaire et la deuxième plus grande ville de la wilaya de Chlef.

La région est influencée par le climat méditerranéen et se caractérise par un climat chaud et tempéré avec des précipitations importantes pendant les mois d'hiver. La température moyenne est de $18,6^\circ \text{C}$ et le total annuel moyen des précipitations est d'environ 585 mm (Kastali, et al., 2021).

Le bassin versant de l'Oued Allala présente une grande diversité de paysages, y compris la présence des zones urbaines, de forêts et de zones agricoles. La partie nord du bassin versant de l'Allala est couverte de forêts de pins. Ainsi, les cultures annuelles comme les céréales couvrent la partie sud du bassin versant. Cette diversité des catégories de l'occupation et

utilisation du sol nécessite une compréhension et identification précise des éléments de paysages exposées au risque d'inondation dans la zone.

Par conséquent, cette zone d'étude a été sélectionnée dans le cadre de la Stratégie nationale de lutte contre les inondations en raison de son importance régionale, de sa situation géographique et du risque élevé de catastrophes naturelles. Pour cette raison, dans ces travaux de thèse, la région du Ténès contenant le bassin versant de l'Oued Allala a été choisie pour établir les méthodologies envisagées.

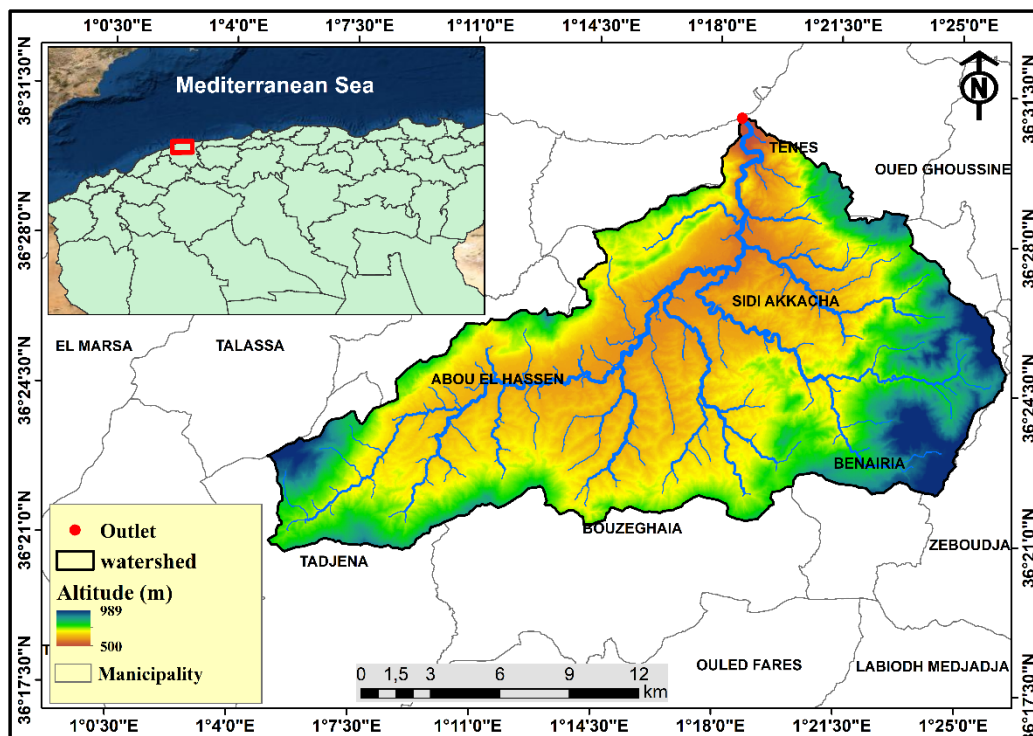


Figure III.7. Localisation et délimitation de bassin versant étudié (Oued Allala- wilaya de Chlef).

III.3.2. Caractéristiques morphométriques et topographiques

Les caractéristiques du bassin versant sont des facteurs importants qui aident à la compréhension de fonctionnement et du régime hydrologique d'un bassin versant. Les caractéristiques déterminées de bassin versant Oued Allala sont principalement : la surface, le périmètre, la pente, la densité du drainage et les altitudes (moyenne, minimale et maximale) Le tableau III.11 illustre les paramètres morphométriques et topographiques dérivés :

Tableau III.11. Paramètres morphométriques du bassin versant Oued Allala.

Bassin versant	Surface (km ²)	Périmètre (km)	Altitude Max (m)	Altitude Min (m)	Altitude Moyenne (m)	Pente Moyenne	Indice de Compacité
Oued Allala	308	99	1032	44	361.10	0.029	1.58

III.3.3. Courbe hypsométrique

Une courbe d'hypsométrie donne une vision synthétique de la pente du bassin et donc du relief. C'est un outil pratique qui permet de déterminer la pluviométrie moyenne d'un bassin versant et fournit un indice du comportement hydrologique et hydraulique du bassin versant et de son système de drainage.

Le Tableau III.12 expose les surfaces hypsométriques présentées par tranche d'altitude et les résultats de calculs de la courbe.

La carte et La courbe hypsométrique sont présentées respectivement dans Figures III.8 et III.9.

Tableau III.12. Surfaces partielles par tranche d'altitude.

Altitude (m)	Altitude Moyenne (m)	Surfaces Partielles (km ²)	Surfaces Partielles (%)	Surfaces Cumulées (km ²)	Surfaces Cumulées (%)
44- 201	122,5	37,39	12,14	37,39	12,14
201- 264	232,5	62,55	20,31	99,94	32,45
264- 328	296	59,65	19,37	159,59	51,82
328- 398	363	46,34	15,04	205,93	66,86
398- 474	436	33,92	11,01	239,85	77,87
474-557	515,5	24,46	7,94	264,31	85,81
557- 653	605	20,91	6,8	285,22	92,61
653- 761	707	14,81	4,81	300,03	97,42
761- 1032	896,5	7,92	2,58	307,95	100




Figure III.8. Carte hypsométrique du bassin versant Oued Allala.




Figure III.9. Courbe hypsométrique du bassin d'oued Allala.

III.3.4. Les caractéristiques climatiques

▪ Température

Toutes les données de température montrent des hivers très froids et des étés très chauds. Les températures moyennes chutent d'au moins (3°C) pendant les trois mois d'hiver (décembre, janvier et février) et d'un maximum (38°C) pendant les trois mois d'été (juin, juillet et août). La température moyenne est de 13,57 °C.

Les Répartitions mensuelles des températures des T_{\max} , T_{\min} et T_{moy} sont illustrées dans le tableau III.13. Les données des températures sont fournies par l'Office National de la Météorologie (ONM).

Tableau III.13. Répartitions mensuelles des températures (ONM :1988-2009)

Mois	T_{\max} (°C)	T_{\min} (°C)	T_{moy} (°C)
Janvier	15	8	11,5
Février	18,2	8,6	13,4
Mars	20,1	10	15,04
Avril	22	10,8	16,4
Mai	24,4	14	19,2
Juin	26,3	16,3	21,3
Juillet	29,9	18	22,45
Aout	27	19,1	23,05
Septembre	25,8	17,3	21,05
Octobre	24,2	15,9	20,05
Novembre	19,8	11	15,4
Décembre	18	9	13,5

▪ Vent

Les vents dominants sont du nord (22 % nord-est, 12 % nord, 27 % nord-ouest) avec une vitesse mensuelle moyenne du vent d'environ 3 m/s, sans variation mensuelle significative (minimum 2,5 m/s), avec vitesse maximale de 3,2 m/s, telle que mesurée par la station Sidi Akkacha de 1993 à 2006 (Tableau III.14).

Tableau III.14. Vitesses moyenne du vent en m/s –Région de Chlef (ONM : 1988-2009).

Mois	Sep	Oct	Nov	Dec	Jan	Fév	Mars	Avril	Juin	Juil	Aout
Vitesses (m/s)	2.9	2.7	2.1	2.6	3.2	2.7	3.4	3.3	3.3	3.3	3.2

III.3.5. Caractéristiques géologiques

Le bassin versant Oued Allala est constitué de formations autochtones et allochtones. Dans sa partie côtière, des nappes géologiques sont chevauchées sur les formations en sédiments en positions autochtonelle. Dans sa partie est, une nappe de Flysch et dans la partie ouest une nappe numidienne. En plus ; la région centrale du bassin versant est formée par des nappes pots-miocènes (sable, graviers, argiles,) (Figure III.10).

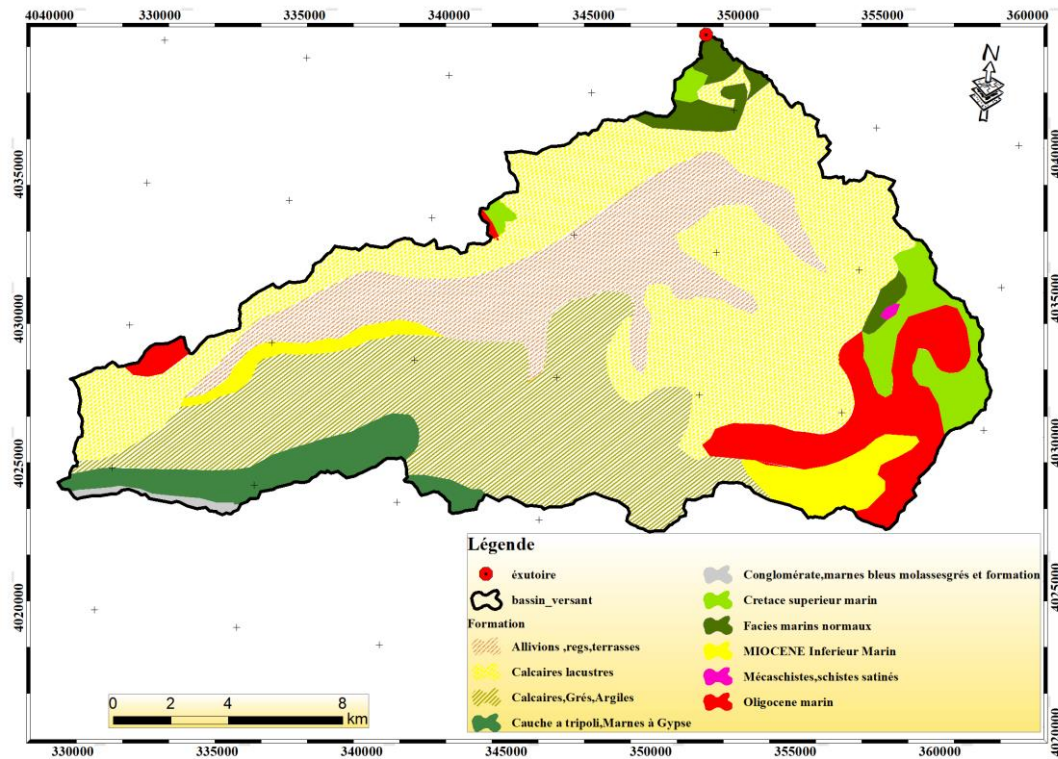


Figure III.10. Carte géologique du bassin versant d'Oued Allala.

III.3.6. Données hydrométriques

Grace à la présence d'une station hydrométrique contrôlant le bassin versant Oued Allala, tous les calculs pour la simulation hydrauliques (décrits au chapitre IV) sont effectués en exploitant une série hydrométrique des débits maxima journaliers provenant de la station hydrométrique Sidi Akkacha sur une période de 45 ans de 1972 à 2017. Les données hydrométriques sont fournies par l'ANRH (Agence Nationale des Ressources Hydriques). Les caractéristiques principales de la station hydrométrique Sidi Akkacha sont montrées dans le tableau III.15.

Tableau III.15. Caractéristiques de la station hydrométrique Sidi Akkacha.

Station	Altitude (m)	Coordonnées géographiques (x, y)	Débit max enregistré (m ³ /s)	Hauteur maximale (m)	Equipement limnimétrique
Sidi Akkacha	86.3	X= 376727 Y= 355590	339	7.1	6 échelles

Conclusion

Dans ce chapitre nous avons présenté les sites d'étude et les données mises en œuvre pour explorer les méthodes proposées de la modélisation de l'occupation du sol, d'une part, et hydraulique et l'évaluation du risque d'inondation d'autre part.

Deux sites d'étude sont sélectionnés pour appliquer les méthodes proposées dans ce travail : Ain Témouchent et Ténès.

Les données spatiales utilisées pour cela sont des données avec différentes résolutions spatiales. Sentinel-1, Sentinel-2, Landsat, Pléiades. L'utilisation de ces différents types de données de télédétection a pour but de tester différentes méthodes sur différents types de données et de tirer des conclusions sur l'apport et l'intérêt de chaque type pour notre problématique.

Pour la modélisation hydraulique, le bassin versant Allala, situé dans le deuxième site d'étude Ténès a été choisi pour réaliser la méthode proposée du fait de la disponibilité des données hydrométriques et *in-situ* nécessaires pour la validation du modèle utilisé. Les données topographiques dérivées des modèles numériques de terrain et de surface ainsi que les résultats de la modélisation de l'occupation du sol seront utilisés dans cette étape.

Les chapitres IV et V décrivent les méthodes et les résultats obtenus avec les méthodes utilisées.

PARTIE III :
APPROCHES
METHODOLOGIQUES

CHAPITRE IV

MODELISATION DE L'OCCUPATION
DU SOL DES ZONES INONDABLES
PAR METHODES D'APPRENTISSAGE
AUTOMATIQUE

Chapitre IV: Modélisation de l'occupation du sol des zones inondables par méthodes d'apprentissage automatique

Introduction

La modélisation de l'occupation du sol joue un rôle important dans diverses applications telles que la surveillance des territoires, la protection de l'environnement, la planification urbaine, la prévention du changement climatique. En particulier, il s'agit d'une base de données essentielle pour la modélisation hydraulique et l'identification des enjeux exposés au risque d'inondation qui est un objectif principal de cette thèse.

L'utilisation de télédétection repose sur la classification d'images satellitaires à haute résolution spatiale et spectrale. Par conséquent, des algorithmes d'apprentissage automatique (*Machine Learning*) sont appliqués pour la classification des images satellites et l'extraction des composants de l'occupation du sol. Dans cette optique, de nombreux images ont été utilisés dont les Sentinel-1, Sentinel-2, Pléiades, Spot et Landsat...etc.

Les images Sentinel avec une résolution exprimée de trois manières : résolution spatiale, résolution spectrale et résolution temporelle, pourraient potentiellement être utiles à l'analyse et la cartographie de l'occupation du sol à différentes échelles. Les produits Pléiades offrent également des possibilités inédites de cartographie de l'occupation du sol à très haute résolution. Ainsi, la disponibilité de milliers d'images offertes par les archives de Landsat et son ancienneté, offre une occasion de suivre l'évolution et les changements de l'utilisation des terres au fil du temps.

Le développement de plusieurs méthodes avancées de traitement d'images satellitaires pour la classification de l'occupation du sol a permis de tester différentes approches appliquées à différentes données satellitaires. Ceci rend les cartes d'utilisation des sols efficaces et de grande qualité. Ainsi, ce chapitre est consacré à l'application des méthodes de *Machine* et *Deep Learning* choisies dans cette thèse pour la cartographie de l'occupation du sol appliquées aux données satellitaires sur deux sites d'étude : Ain Témouchent et Ténès. Comme nous l'avons évoqué dans les chapitres précédents, ces deux sites ont été choisis en raison de leur exposition face au risque d'inondation chaque année. Par conséquent, cela nécessite une base de données de haute qualité des cartes d'occupation pour les zones sujettes aux inondations.

Les résultats de cette partie ont déjà fait l'objet de publications scientifiques dans des revues et des conférences. La première section décrit les méthodes utilisées pour traiter l'ensemble des

données satellitaires afin d'obtenir des cartes d'occupation du sol. La seconde section présente les résultats de classification obtenus dans les deux sites étudiés ainsi que les résultats de l'évaluation de la performance de ces classifications. Enfin, des discussions de ces résultats sont abordées dans la dernière partie.

IV.1. Approche méthodologique pour la classification de l'occupation du sol : Application aux sites d'études : Ain Témouchent et Ténès

IV.1.1. Prétraitements des données satellitaires

IV.1.1.1. Prétraitements des données Sentinel-1

Avant d'être utilisées dans le processus de fusion et de classification, les images Sentinel-1 requièrent un prétraitement indispensable pour améliorer leur qualité brute. Cette étape consiste essentiellement à calibrer, filtrer et corriger géométriquement les images.

Ces prétraitements ont été effectués par l'outil Sentinel ToolBox (Figure IV.1) implémenté dans le logiciel SNAP (Sentinel Application Platform) développé par l'ESA (Agence Spatiale Européenne) pour le traitement des données Sentinel (<https://step.esa.int/main/toolboxes/snap/>).




Figure IV.1. Interface de logiciel SNAP

Il s'agit des traitements suivants :

▪ **Calibration radiométrique**

La calibration radiométrique est le premier traitement à réaliser sur les images Radar brutes. L'étalonnage radiométrique est essentiellement basé sur l'expression de la rétrodiffusion en termes de coefficient de rétrodiffusion (nombres pour chaque pixel). Ce coefficient est proportionnel au rapport de la puissance reçue par l'antenne sur la puissance émise. Il s'agit donc d'une grandeur physique sans dimension qui dépend non seulement de paramètres spécifiques du capteur, tels que l'angle d'incidence, la polarisation et la longueur d'onde, mais également de paramètres de surface qui définissent les propriétés diélectriques et géométriques du capteur (humidité du sol, rugosité de surface et diffuseur). Le but du calibrage est donc de corriger la radiométrie de l'image pour que les valeurs des pixels représentent bien la rétrodiffusion radar de la surface réfléchissante. L'étalonnage est également essentiel pour l'utilisation quantitative des données radar.

▪ **Réduction du chatoiement ou du Speckle**

Le chatoiement est le bruit multiplicatif représenté par des interférences de l'accumulation et de la rupture aléatoires des ondes réfléchies, donnant lieu au bruit sel et poivre dans toute l'image qui est typique de l'imagerie radar (Maher, 1997). Ce bruit se produit généralement lors de la numérisation d'une image. Par conséquent, l'objectif de l'application de filtre de Speckle est de supprimer ce bruit afin de faciliter l'interprétation et l'utilisation des images. En préservant les éléments structurants de l'image, le principe est de remplacer chaque niveau de gris par une combinaison linéaire des niveaux de gris des points voisins. Plusieurs algorithmes ont été développés dans le contexte de réduction de chatoiement dans les images radar, par exemple (Bovik et *al.*, 1983). Dans le présent traitement, l'algorithme (Lee et *al.*, 1983) intégré dans SNAP a été utilisé. Cet algorithme est initialement basé sur le calcul de paramètres statistiques tels que les moyennes locales et les variances. Ensuite, une minimisation de l'erreur quadratique moyenne est effectuée pour diminuer la dispersion et maintenir la moyenne des pixels. La spécificité de cet algorithme est de réduire le chatoiement tout en conservant les contours et les contrastes des objets.

▪ **Correction géométrique**

Le mouvement orbital vers le haut ou vers le bas (ascendant ou descendant) résulte des distorsions et les changements géométriques au niveau de l'image brute. Ainsi, des effets du terrain et de la géométrie de visualisation latérale du capteur apparaissent en forme sombre sur l'image : cela est appelé effet d'ombre. Par conséquent, la correction géométrique permet de

corriger les images de ces distorsions géométriques à l'aide d'un modèle numérique du terrain. Ensuite, les images sont projetées selon un système de coordonnées géographiques défini selon la situation de la zone étudiée. Le système de projection utilisé est celui de système WGS 84 / UTM zone 31N.

IV.1.1.2. Prétraitements des données Sentinel-2

Les images Sentinel-2 sont disponibles en téléchargement avec plusieurs niveaux de corrections. Les niveaux des images disponibles pour les site d'étude sont le 2A ; où les images sont déjà corrigées, contrairement au niveau 1C qui nécessite une correction atmosphérique.

Par conséquent, pour les images acquises à ce niveau, une correction atmosphérique a été effectuée à travers l'extension de l'algorithme « Sen2Cor » du logiciel SNAP. Toutes les images optiques sont ensuite rééchantillonnées afin que toutes les bandes aient la même résolution spatiale (10 m). Pour cela, la méthode de rééchantillonnage bicubique a été utilisée pour le rééchantillonnage des bandes de Sentinel-2. L'avantage de cette méthode est qu'elle représente un bon compromis entre la qualité de rééchantillonnage et temps de calcul.

Les autres images utilisées, Pléiades et Landsat 5 TM, sont déjà corrigées et ne nécessitent aucun traitement de correction. Cependant, un mosaïquage d'images a été effectué sur une plateforme SIG pour extraire les régions d'intérêt pour les traitements ultérieurs.

IV.1.2. Calcul des indices spectraux et fusion des données optiques radar pour le site d'étude Ain Témouchent

La compréhension des processus physiques sur la terre et la caractérisation des propriétés biophysiques de la surface de la terre sont souvent basées sur la réponse spectrale de la surface cible.

Ces propriétés biophysiques peuvent être évaluées par un certain nombre d'indices spectraux développés après traitements des données d'images satellitaires. Les indices spectraux sont basés sur la réponse spectrale de la surface de terre, et dépendent des caractéristiques physiques de la surface. Ils sont utilisés de manière significative dans le processus de classification et permettent d'améliorer la précision de la classification de l'occupation du sol. Ces indicateurs sont divisés en deux grandes catégories représentant : (a) la végétation et (b) les conditions du sol de la zone (Polykretis et *al.*, 2020 ; Varade et *al.*, 2019). Dans cette étude, principalement trois indices différents ont été extraits des bandes Sentinel-2, à savoir, l'indice de végétation par différence normalisée (NDVI), l'indice de la teneur en eau par différence normalisée (NDWI) et l'indice d'urbanisation de différence normalisée (NDBI). Ces indices sont détaillés

dans ce qui suit. Le calcul de ces indicateurs se fait à l'aide de fonctions disponibles dans le logiciel SNAP. Le choix de ces indicateurs est principalement dû à :

- La présence de végétation dans les sites étudiés (forêt, terres agricoles, etc.)
 - La présence de zones urbaines exposées au risque d'inondation. Par conséquent, l'utilisation de l'indice NDBI permet de mieux identifier les zones urbaines.
 - Le NDWI est utilisée principalement pour identifier les surfaces humides.
- **Le NDVI (*Normalized Difference Vegetation Index*)** (Rouse, et *al.*, 1974) ou indice de végétation par différence normalisée est un très bon indicateur de détection de la verdure et la qualité de végétation. Souvent utilisé en télédétection, le NDVI se produit à partir des canaux, rouge (R) et proche infrarouge (NIR) (Figure IV.2), est donné par la formule :

$$\frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (1)$$

Où NIR et RED sont les valeurs de réflectance dans les bandes du proche infrarouge et du rouge visible, respectivement.

Cet indice prend des valeurs comprises entre -1 et +1. Les valeurs négatives présentent les surfaces autres que la couverture végétale, à savoir la neige, l'eau ou les nuages, ce qui est expliqué dans la formule (la valeur de la réflectance dans le rouge est supérieure à celle du proche infrarouge). Par ailleurs, la végétation en bonne santé a des valeurs comprises entre 0,3 et 0,8. Les sols nus des valeurs proches de 0,1 – 0,2.




Figure IV.2. Indice de végétation par différence normalisée (NDVI) calculé par les bandes de Sentinel-2 (région de Ténès).

- **Le NDWI (*Normalized Difference Water Index*)** (McFEETERS, 1996), ou l'indice de la teneur en eau par différence normalisée, se produit par les canaux proche infrarouge (NIR) et infrarouge à ondes courtes (SWIR) (figure IV.3). Il est calculé selon le principe de la forte capacité d'absorption de l'eau et du faible rayonnement dans la gamme de longueurs d'onde visible à infrarouge. Dans la plupart des cas, l'indice NDWI peut améliorer efficacement les informations sur l'eau. Ses valeurs varient en fonction de la teneur en eau de la végétation, l'indice est obtenu par la formule:

$$\frac{\rho_{NIR} - \rho_{SWIR}}{\rho_{NIR} + \rho_{SWIR}} \quad (2)$$




Figure IV.3. Indice de la teneur en eau par différence normalisée (NDWI) calculé par les bandes de Sentinel-2 (région de Ténès).

- **L'indice d'urbanisation par différence normalisée (NDBI)** a été proposé par (Zha, et *al.*, . Son objectif est de cartographier automatiquement les zones urbaines bâties. Cet indice est fourni par les bandes infrarouge moyen (SWIR) et proche infrarouge (NIR) (figure IV.4) où les zones bâties ont une réflectance élevée dans la bande SWIR et une réflectance faible dans la bande NIR. Le NDBI est calculé par la formule :

$$\frac{\rho_{SWIR} - \rho_{NIR}}{\rho_{SWIR} + \rho_{NIR}} \quad (3)$$




Figure IV.4. Indice d'urbanisation par différence normalisée (NDBI) calculé par les bandes de Sentinel-2 (région de Ténès).

IV.1.3. Fusion des images Sentinel-1 et Sentinel-2

Après avoir terminé les prétraitements nécessaires de toutes les images et calculé les indices spectraux sélectionnés pour l'étude, nous avons effectué une étape de combinaison pour une classification basée sur l'ensemble de données radar et optiques fusionnées. A noter que le site choisi pour la fusion optique/radar est celui d'Ain Témouchent. Le type de fusion choisi est celui d'avant classification, procédé sur deux phases :

- Une fusion de l'ensemble des données provenant d'un même capteur, à savoir les bandes rééchantillonnées, couches NDVI et couches NDWI pour le Sentinel-2, et de toutes les bandes de toutes les dates acquises pour Sentinel-1.
- Une fusion des deux images finales provenant de différents capteurs.

A la fin de cette étape nous obtenons une image multitemporelle et multi-capteurs. Cette image sera utilisée dans le processus de classification (figure IV.5).




Figure IV.5. Sous ensemble de l'image provenant de la fusion optique et radar (Sentinel-1 et Sentinel-2).

La méthodologie employée est illustrée dans la figure IV.6 :

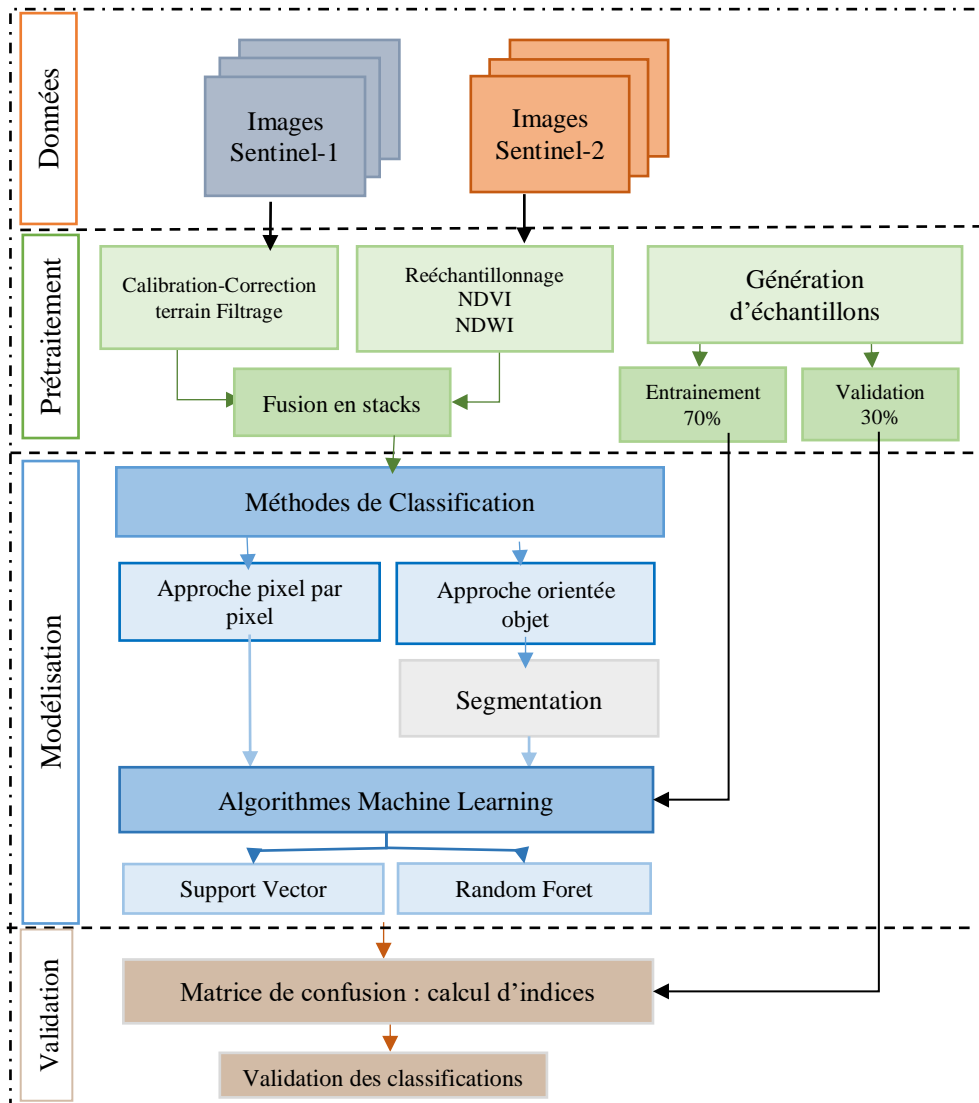


Figure IV. 6. Méthodologie employée pour la classification de l'occupation du sol en utilisant l'approche synergique des données optiques et radar.

IV.1.3. Définition des classes de l'occupation du sol

Les catégories d'occupation du sol ont été définies à l'aide d'une analyse visuelle et d'une interprétation de l'image THRS de Pléiades, produisant 10 classes prédominantes : forêts, terres cultivées, sols nus, zones bâties, terres stériles, terres suivies, terres non cultivées, routes, stades et eau. La résolution spatiale de l'image Sentinel-2A étant inférieure à celle des données Pléiades, six catégories de l'occupation du sol correspondantes ont été identifiées : eau, terres cultivées, terres non cultivées, sols nus, zones bâties et forêts.

L'interprétation des classes issues de la classification non supervisée selon une nomenclature thématique préétablie se fait généralement par analyse visuelle et interprétation de données satellitaires à très haute résolution spatiale en l'absence de vérité terrain et de cartes de référence. Dans notre cas, une interprétation des images d'archives Google Earth et des images THRS

Pléiades a été réalisée pour la sélection de classe en raison du manque de cartes de référence d'occupation des sols sur le site d'étude.

De plus, la littérature suggère que plusieurs niveaux de catégories peuvent être spécifiés pour l'identification de l'occupation du sol (du moins détaillé au plus détaillé). Par ailleurs, notre objectif étant de caractériser les classes d'occupation du sol exposées au risque d'inondation et compte tenu de la résolution spatiale des données utilisées, nous avons définies les classes selon deux niveaux différents.

Ces choix sont explicités dans les tableaux IV.1 et IV.2 où figurent les classes d'occupation du sol choisies leur description pour chaque jeu de données. Quelques exemples de classes d'occupation du sol définies sont montrés sur la figure IV.7.

Au total et selon nos besoins, 10 catégories de l'occupation réparties sur deux niveaux ont été définies dans cette étude, introduisant essentiellement : eau, routes, constructions, terres agricoles, terres non agricoles, jachère, stades, maisons vertes, sols nus et forêts. Les dix classes représentent le niveau 2 le plus détaillé. Certaines classes ont été fusionnées pour représenter le niveau 1 en tenant compte la résolution spatiale de l'image d'entrée introduisant les classes : eau, constructions, végétation ou forêts, routes, terres agricoles et sols nus.

Tableau IV.1. Niveau 1 de sélection et de nomenclature des classes d'occupation du sol.

Donnée satellitaire	Objectif	Classe	Description
Sentinel-1 Sentinel-2	Classification provenant de fusion otique radar	Eau	Mer, barrages, cours d'eaux et rivières
		Sols nus	Terres non agricoles et surfaces agricoles non cultivées.
		Routes	Routes
		Terres agricoles	Surfaces couvertes par les cultures agricoles
Landsat	Classification et évaluation des changements de l'occupation du sol	Constructions	Constructions rurales, bâtiments urbains, constructions commerciales, industrielles et ports.
		Végétation	Forêts, végétation urbaine, végétation moyenne... etc

Tableau IV.2. Niveau 2 de sélection et de nomenclature des classes d'occupation du sol.

Type de données	Objectif	Classe	Description
Pléaïdes Sentinel-2	Classification de l'occupation du sol	Eau	Mer, barrages, cours d'eaux et rivières
		Routes	Routes
		Constructions	Constructions rurales, bâtiments urbains, constructions commerciales, industrielles et ports.
		Forêts	Arbres, végétation moyenne et forêts
		Terres agricoles	Surfaces couvertes par les cultures agricoles
		Terres non agricoles	Terres abandonnées
		Sols nus	Zones sans cultures
Pléaïdes	Classification de l'occupation du sol	Jachère	Zone sans culture préparées pour la culture
		Maisons vertes	Maisons agricoles
		Stades	Stades et parc avec gazon artificiel




Figure IV.7. Exemples de classes d'occupation du sol définies

IV.1.4. Génération d'échantillons pour le processus d'entraînement et de validation de la classification.

L'étape de préparation des échantillons est une étape très importante dans le processus de classification et les résultats de cette étape peuvent affecter la précision de la classification. La génération des échantillons a été divisée en deux catégories : les échantillons d'entraînement et les échantillons de validation.

Ce processus a été effectué à l'aide du logiciel QGIS (*Quantum Geographic Information System*) (version : 3.16.0) fournissant deux ensembles de données vectorielles. Le vecteur d'entraînement a été utilisé dans le processus de l'entraînement de classification, tandis que le vecteur de validation a été utilisé dans l'étape de l'évaluation de précision des classifications. Les sites d'entraînement et de validation choisis sur l'image pour la création de échantillons sont différents.

IV.1.5. Méthodes de Machine Learning pour la classification

Pixel par pixel et orientée objet (OBIA) sont les méthodes de machine Learning choisies pour la classification de l'ensemble des images satellitaires. Concernant la méthode OBIA, l'algorithme multirésolution a été choisi pour la segmentation de l'image d'entrée. Dans ce qui suit, nous détaillons les méthodes et les algorithmes utilisés.

IV.1.5.1. Pixel par pixel

La méthode pixel par pixel est basée sur la réponse spectrale des pixels de l'imagerie satellitaire. Cette méthode est largement utilisée en télédétection depuis plusieurs années. Dans notre étude, nous avons utilisé la bibliothèque d'algorithmes OTB (*Orfeo ToolBox*) pour implémenter la méthode pixel par pixel. Pour cela, deux étapes nécessaires à la classification pixel par pixel ont été appliquées, principalement ; entraînement et validation de la classification à l'aide de l'ensemble de données d'entraînement et de validation.

IV.1.5.2. Orientée objet

Contrairement à la méthode basée sur les pixels, la classification de l'occupation du sol par la méthode OBIA repose sur une étape fondamentale : la segmentation qui vient avant l'entraînement des modèles de classifications. Cette étape consiste à regrouper les pixels voisins selon des critères spectraux, textuels et contextuels.

Dans ce cas, l'algorithme Multirésolution a été choisi pour le processus de segmentation.

▪ Multi-resolution Segmentation

Comme l'OBIA prend en compte les informations spectrales, textuelles et contextuelles des pixels, la segmentation est une étape importante de ce processus. Le processus de segmentation regroupe les pixels voisins ayant des caractéristiques similaires.

En effet, pour chaque image, en utilisant les bandes spectrales d'entrée, l'algorithme de segmentation multirésolution a été utilisé pour générer des objets homogènes (Batz and Schäpe, 2002). La segmentation Multirésolution est un algorithme puissant conçu pour segmenter itérativement une image satellite en objets selon des conditions imposées par l'utilisateur (Belgiu, Csillik 2018).

Dans ce travail, l'algorithme Multirésolution a été appliqué et implémenté dans Trimble eCognition Developer (version 10.0) aux images satellitaires d'entrée pour fournir la couche de segmentation (quelques exemples sont montrés dans la figure IV.8).

La création des objets à l'aide de cet algorithme repose sur l'homogénéité ou l'hétérogénéité des objets de l'image, en fonction de critères spectraux et de forme (*eCognition* 2021). La taille des objets est définie par un paramètre d'échelle. L'hétérogénéité des objets est définie par les paramètres de forme et de couleur, dans lesquels leur proportion est spécifiée par le paramètre de forme. Par exemple, une valeur de paramètre de forme = 0.1 signifie que l'hétérogénéité est influencée à 10 % par la forme et à 90 % par la couleur (Lourenço et al., 2021; Platt et al., 2016). De même, le paramètre de forme est défini par deux composantes, la compacité et la douceur, dont la proportion est spécifiée par le paramètre de compacité. Par exemple une valeur de paramètre de compacité = 0.9 signifie que l'hétérogénéité est influencée à 90 % par la compacité et à 10 % par la douceur.

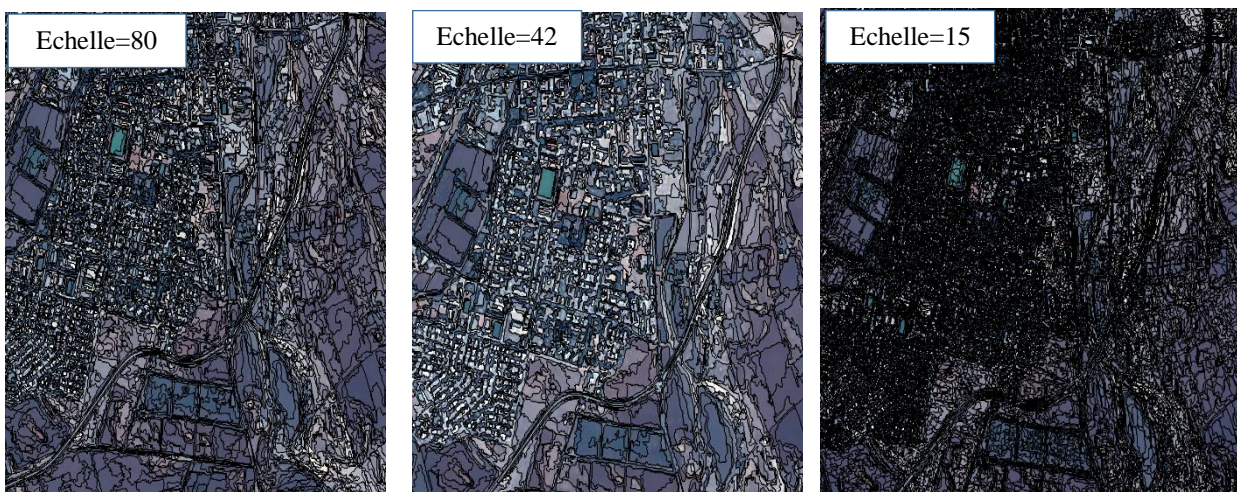


Figure IV.8. Segmentation Multi-résolution d'une image Pléiades à différentes valeurs de paramètre échelle.

IV.1.5.3. Algorithmes de classification

Deux algorithmes de Machine Learning ont été choisis pour effectuer les classifications pixel par pixel et OBIA ; Random Forest (RF) et Support Vector Machine (SVM). Ces algorithmes ont été fréquemment appliqués dans les analyses de télédétection, ils sont reconnus pour leurs caractéristiques puissantes et sont souvent considérés comme les techniques par défaut pour la modélisation de l'occupation du sol (Dabija *et al.*, 2021 ; Adugna *et al.*, 2022 ; Jamali, 2021).

RF est un puissant algorithme de Machine Learning doté d'excellentes capacités de cartographie de l'occupation du sol à l'aide de différentes données sources (Heryadi, 2020 ; Liu *et al.* 2019). C'est un modèle non paramétrique qui crée de multiples arbres de décision, chaque arbre étant construit en assignant la classe la plus populaire aux images d'entrée. Dans la classification de l'occupation du sol, le classificateur RF s'est avéré cohérent et relativement efficace, nécessitant peu de paramètres imposés par l'utilisateur et produisant une précision OA (*Overall Accuracy*) souvent cohérent ou meilleur que d'autres algorithmes (par exemple, les arbres de décision classiques et le maximum de vraisemblance) (Lawrence *et al.*, 2006). Pour l'entraînement du classifieur RF, deux paramètres importants doivent être attribués : le nombre maximum d'arbres (*Ntree*) et le nombre de caractéristiques à sélectionner pour chaque arbre (*Mtry*). Ensemble, ces deux paramètres ont un impact important sur la performance de la classification (Belgiu, Drăguț, 2016 ; Thanh Noi et Kappas 2017).

Par ailleurs, le SVM est un algorithme non paramétrique pour les analyses d'images de classification et de régression. Il est souvent utilisé dans les tâches de cartographie de l'occupation du sol, car c'est un classificateur discriminant qui minimise l'imprécision des images en identifiant dans un hyperplan les solutions qui transforment les données en classes prédéfinies. Dans les cas où les caractéristiques des données sont inséparables, le SVM possède une fonction noyau qui projette les données dans des fonctions d'ordre supérieur (Wang *et al.*, 2016). Plusieurs caractéristiques de noyau sont utilisées dans le modèle SVM : la fonction gaussienne à base radiale (RBF), ainsi que les fonctions polynomiales, linéaires et sigmoïdes. Ici, un noyau RBF a été appliqué pour la classification SVM. Les paramètres C et γ sont les deux composantes fondamentales qui contrôlent la performance du SVM lorsque la RBF est considérée comme la fonction noyau (Foody *et Mathur* 2004 ; Huang *et al.*, 2002). En effet, le paramètre C est utilisé pour contrôler l'ampleur des pénalités pour régulariser l'ensemble des données d'entraînement mal classées et joue un rôle important en affectant la précision et/ou la capacité de généralisation de l'algorithme (Adugna *et al.*, 2022).

L'effet du paramètre γ est le contrôle des largeurs de noyau, de même, dans la classification SVM basée sur le noyau RBF, l'effet de γ est similaire à celui de C, car si une valeur est élevée lors de l'attribution, le modèle est surajusté et la généralisation n'est pas bonne (Foody *et* Mathur 2004).

Un large jeu de données a été testé pour optimiser et choisir les valeurs des paramètres des deux algorithmes, dans le but de créer le modèle de classification le plus efficace. Pour l'algorithme RF, les valeurs de Ntree= 50, 100, 200, 300, 400, 500 et 1000 ont été testées en maintenant la valeur par défaut de Mtry. En outre, la meilleure valeur déterminée de Ntree a été définie comme valeur par défaut. Un ensemble de valeurs de Ntry a été expérimenté entre 2 et 75 (2, 5, 10, 15, 20, 25,30, 40, 50 et 75). Le même processus a été suivi en considérant l'algorithme SVM, avec des valeurs pour le paramètre C comprises entre 1 et 20 (C =1, 2, 4, 5, 8, 10, 15, 20), et entre 0,5 et 5 (γ = 0,5, 1, 2, 3, 4, 5) pour le paramètre Gamma. Les valeurs des hyperparamètres dérivés pour le processus d'optimisation utilisant la méthode de validation croisée sont présentées dans le tableau IV.3. Il convient de noter que la méthode basée sur les pixels a été réalisée par le biais de la bibliothèques OTB, et que la méthode OBIA a été réalisée à l'aide du logiciel eCognition.

Tableau IV.3. Les valeurs des hyperparamètres dérivés pour le processus d'optimisation.

Image	Méthode	Algorithme	Hyperparamètres
image Pléiades	OBIA	RF	Ntree : 300 Mtry : 10
		SVM	C : 1 Gamma : 0.5
	Pixel	RF	Ntree : 100 Mtry : 10
		SVM	C : 1 Gamma : 0.5
image Sentinel-2	OBIA	RF	Ntree : 200 Mtry : 10
		SVM	C : 2 Gamma : 0.1
	Pixel	RF	Ntree : 100 Mtry : 2
		SVM	C : 2 Gamma : 1
Image fusionnée Sentienl-1 et Sentienl-2	OBIA	RF	Ntree : 100 Mtry : 10
		SVM	C : 0.1 Gamma : 0.5
	Pixel	RF	Ntree : 1000 Mtry : 10
		SVM	C : 1 Gamma : 0.5

IV.1.6. Méthode CNN-OBIA

Comme mentionné précédemment, très récemment, les modèles *Deep Learning* combinés avec la méthode OBIA fréquemment émergés dans les applications de classification des images satellitaires, en particulier, l'occupation du sol. Cela est dû à leur énorme potentiel d'extraction des caractéristiques d'image à haut niveau. Dans ce sens, l'objectif principal de l'application de la méthode OBIA-CNN est de cartographier l'occupation du sol dans les sites étudiés et extraire ses éléments avec une grande précision.

Les principales données de télédétection utilisées pour tester la méthodologie proposée sont les images Pléiades et des données Sentinel-2. La méthodologie employée dans ce contexte est décrite dans la figure IV.9. En outre, les sous-objectifs suivants ont été pris en compte dans l'application de la méthodologie de la méthode CNN-OBIA :

- Utilisation d'un modèle CNN simple avec le moins de couches possible intégré au logiciel eCognition pour limiter la demande de calcul,
- Optimisation des hyperparamètres du CNN pour améliorer la précision de la classification,
- Comparer la méthode proposée avec les méthodes d'apprentissage automatique (algorithmes RF et SVM),
- Et, évaluer la contribution de chaque ensemble de données utilisé en termes de précision de la classification finale de l'occupation du sol.

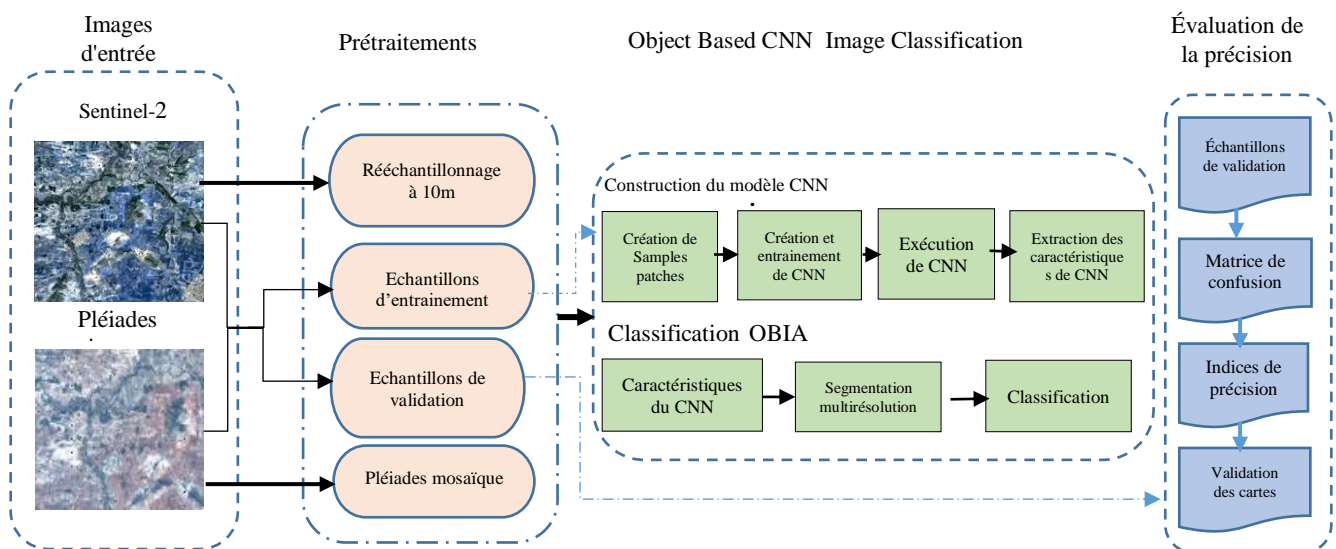


Figure IV.9. Organigramme descriptif de classification de l'occupation du sol par la méthode CNN-OBIA.

IV.1.6.1. Présentation d'architecture du modèle CNN

Dans la conception d'un modèle CNN, il est essentiel de trouver l'architecture appropriée capable de répondre aux besoins de la recherche. Étant donné que le processus CNN de dérivation des couches de sortie est construit en plusieurs étapes produisant un ensemble de couches de caractéristiques (Csillik et al. 2018; Heryadi, Miranda 2020), la formation de tout modèle CNN permet une combinaison optimale des paramètres du modèle. Ainsi, l'optimisation des hyperparamètres du CNN (par exemple, la taille de l'échantillon, les couches cachées et le taux d'apprentissage) est une étape primordiale pour obtenir un modèle performant.

Ici, l'architecture CNN a été créée dans *Trimble eCognition Developer* (version.10.0). Les principales couches caractérisant la conception structurelle CNN mises en œuvre sont : les couches cachées (*hidden*), de convolution, de mise en commun (*pooling*) et entièrement connectées (*fully-connected*).

Le processus de création d'un modèle comprend trois étapes principales : (1) création de patches d'échantillons, (2) génération et entraînement du modèle, et (3) application du modèle. Le logiciel eCognition est avantageux pour sa capacité intégrative à effectuer des classifications CNN avec OBIA. Les architectures détaillées de CNN utilisant les données d'entrée de Pléiades et Sentinel-2 sont présentées dans les figures IV.10 et IV.11.

En outre, pour chaque image d'entrée, un modèle optimal CNN a été adopté pour produire une classification d'après plusieurs études précédentes (Ghorbanzadeh et al. 2021 ; Jin et al. 2019b ; Liu et al. 2019a).




Figure IV.10. Architecture de modèle CNN générée à partir de l'image Pléiades.




Figure IV.11. Architecture de modèle CNN générée à partir de l'image Sentinel-2.

IV.1.6.2. Génération d'échantillons patches étiquetés pour le modèle profond CNN

La première étape de la création d'un modèle CNN consiste à créer des échantillons patches. Ces échantillons sont étiquetés à partir de l'image d'entrée entière. La taille des échantillons est considérée comme l'un des paramètres les plus critiques dans l'architecture optimale d'un réseau CNN (Ghorbanzadeh, Blaschke 2019); ainsi, différentes tailles ont été considérées pour les deux types d'images : 8×8 , 10×10 , 16×16 , 20×20 , 32×32 et 64×64 pixels.

A l'aide d'une méthode de validation croisée, la taille du patch d'échantillonnage de 16×16 a été attribuée pour les données des Pléiades, et de 32×32 pour les données de Sentinel-2A. Le nombre d'échantillons et les bandes de l'image sont des paramètres indispensables à la création du modèle et doivent être examinés. Ainsi, dans cette étape, pour chaque type d'image d'entrée, toutes les bandes spectrales ont été utilisées, et un ensemble de 10 000 échantillons étiquetés a été généré pour chaque modèle créé.

IV.1.6.3. Création et entraînement du modèle CNN

Dans cette étape, le modèle CNN a été dérivé en appliquant la fonction de l'algorithme CNN intégré avec eCognition en utilisant toutes les bandes spectrales des données comme entrées et les classes de l'occupation du sol générées comme sorties.

Le nombre de couches cachées, les cartes de caractéristiques, la taille des noyaux et les couches de mise de commun maximale sont des paramètres définis par l'utilisateur. Ainsi, pour les données Pléiades, deux couches cachées ont été construites pour le modèle CNN après une exécution par validation croisée et évaluation des résultats de précision de la sortie CNN. Une couche en mise de commun maximale (max pooling) a été appliquée dans l'étude ici avec un nombre pair d'unités. Le but était de diminuer le nombre d'unités en ne conservant que la

réponse maximale de plusieurs unités dans la couche cachée (*eCognition* 2021). De même, après une méthode de validation croisée, une couche de convolution a été mise en œuvre pour chaque couche avec une valeur de taille de noyau de 3×3 pixels pour la première couche cachée, et de 5×5 pixels pour la deuxième couche.

Cependant, dans le cas de la création d'un modèle CNN utilisant l'image Sentinel-2A, une seule couche cachée a été créée et appliquée avec une mise en commun maximale, une couche de convolution et une taille de noyau de 7×7 pixels, sur la base des résultats de précision du CNN. Ensuite, le modèle CNN a été entraîné en utilisant les patches d'échantillons étiquetés et les configurations de paramètres, et les poids du modèle ont été ajustés en utilisant la rétropropagation. Dans cette étape, le réglage des paramètres est important, plus particulièrement, le taux d'apprentissage. Ce paramètre important contrôle la taille du pas d'entraînement pour chaque itération d'entraînement ; ainsi, des taux inappropriés peuvent conduire à une divergence ou une convergence plus lente (Jin et al. 2019b). Par conséquent, des valeurs de 0,0006, 0,0009, 0,001, 0,005 et 0,01 ont été testées. Ici, notons que les valeurs inférieures ralentissent le processus d'apprentissage en trouvant des minima locaux ou des poids sous-optimaux, tandis que les valeurs supérieures accélèrent le taux avec un risque accru de manquer les minima optimaux (*eCognition* 2021).

Enfin, les résultats de précision ont montré qu'un taux de 0,0006 représentait le plus précisément la quantité d'ajustement de poids lors de l'optimisation statistique avec descente de gradient. Les pas d'entraînement et les échantillons à générer pour les classes ont été définis sur 5000 et 50 respectivement pour les deux types de données d'entrée.

IV.1.6.4. Application du modèle CNN

Une fois que le modèle CNN est construit et entraîné, et que les valeurs OA du modèle CNN construit sont vérifiées à l'aide de la fonctionnalité intégrée d'eCognition, des couches entièrement connectées (heatmaps) correspondant aux classes de l'occupation du sol après l'exécution du modèle ont été générées.

Ces couches ont une unité pour chaque catégorie prédite par CNN, où deux possibilités existaient : une valeur proche de 1 indique une plus grande probabilité de la catégorie, tandis qu'une valeur proche de 0 indique une plus faible probabilité. Pour l'imagerie Pléiades, 10 couches (heatmaps) ont été créées. En revanche, l'image Sentinel-2A a produit 6 couches (heatmaps). La couche générée correspond à des catégories d'occupation du sol définies par le fichier vectoriel d'échantillons d'entraînement en entrée.

IV.1.6.5. Post classification avec OBIA

Étant donné que le modèle CNN a été exécuté au niveau du pixel, la classification du modèle conjoint à l'aide d'OBIA nécessite de classer l'image d'entrée entière au niveau objet en utilisant cette dernière approche.

Dans cette étape, la méthode OBIA a été exécutée en utilisant les couches de sortie du modèle CNN (les heatmaps) comme entités d'entrée. Les données Sentinel-2 et Pléiades ont été transformées en images segmentées par l'algorithme multirésolution. La segmentation multirésolution est un modèle de croissance de région, et assemblent les pixels pour fournir des objets par itération, tout en maintenant les conditions homogènes définies par l'utilisateur.

Par essais et erreurs, différentes valeurs de paramètres d'échelle des deux ensembles de données d'entrée ont été testées afin d'obtenir la plus grande précision de classification possible. Grâce à la validation croisée des images Pléiades et Sentinel-2, des valeurs de 15 et 5 ont été sélectionnées pour les paramètres d'échelle. Les autres critères d'homogénéité (forme et compacité) ont été fixés à des valeurs par défaut de 0,1 et 0,5.

IV.1.7. Détection des changements de l'occupation du sol dans le bassin versant de l'Oued Allala.

IV.1.7.1. Présentation générale de la méthodologie employée

Par un processus consécutif, nous avons cartographié et évalué les changements de l'occupation et de l'utilisation des sols dans le bassin versant de l'Oued Allala sur 21 ans. Des méthodes de télédétection combinées à des applications SIG ont été utilisées (figure IV.12).

Les données Landsat 5-TM et Sentinel-2 couvrant trois années (1999, 2009 et 2020) ont été acquises pour établir la classification en suivant deux étapes essentielles : 1) la méthode d'analyse d'image basée sur les objets (OBIA) a été appliquée pour fournir les cartes l'occupation et l'utilisation des sols avec deux algorithmes de Machine Learning ; Random Forest (RF) et Support Vector Machine (SVM). Ensuite, 2) l'évaluation des changements d'occupation du sol a été réalisée dans le logiciel ArcMap (version 10.8.1) par une analyse de post classification et calcul d'une matrice de confusion.

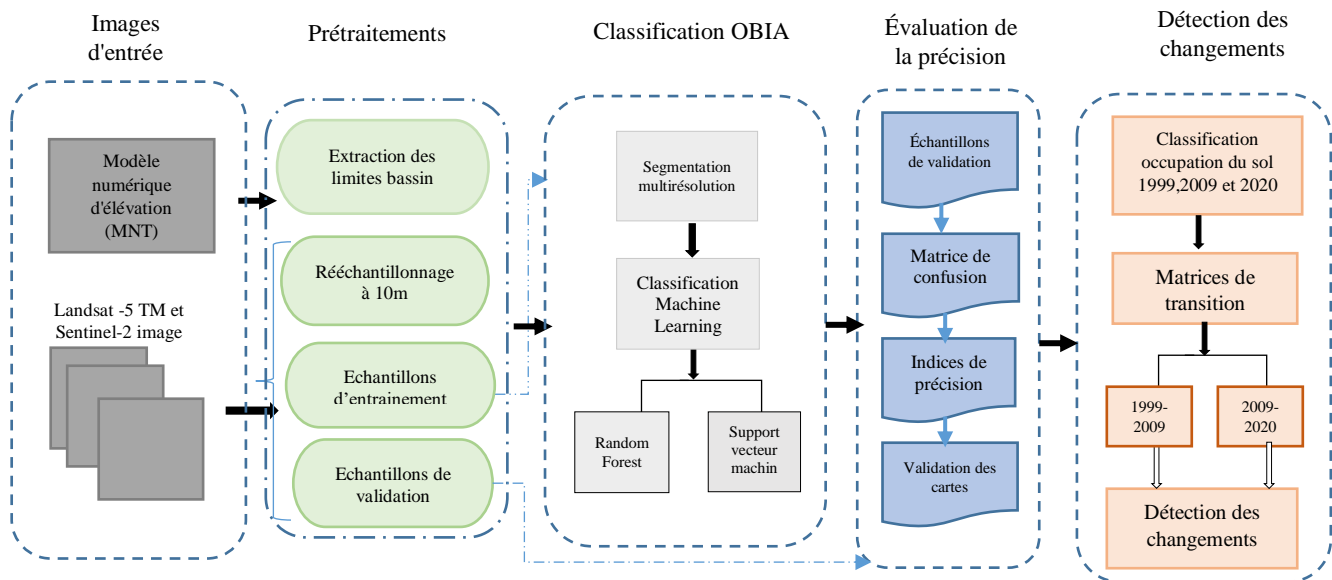


Figure IV.12. Organigramme de la méthodologie proposée pour la classification et l'évaluation des changements de l'occupation du sol du bassin versant de l'Oued Allala.

Deux types différents d'imagerie satellitaire ont été acquis à partir des capteurs Landsat-5 TM et Sentinel-2 pour classifier et détecter les changements de l'occupation du sol dans le bassin versant de l'Oued Allala. Les images Landsat-5 TM ont déjà été corrigées. Pour les images Sentinel-2, un rééchantillonnage à une résolution spatiale de 10 m a été appliqué dans le logiciel de la plateforme Sentinel (SNAP) avant d'utiliser l'image dans le processus de classification (Zaabar, et al., 2021). Les dates ont été choisies en fonction de l'absence de la couverture nuageuse dans les images, et de leur disponibilité pour la même saison sur les trois ans, pour une détection précise des changements de l'occupation et l'utilisation des sols.

Pour l'entraînement et la validation de la classification de l'occupation du sol et en se basant sur des images à très haute résolution (THRS), des données d'entraînement et de validation ont été générées.

Compte tenu de la résolution de l'imagerie Landsat-5 TM et de l'analyse de la zone d'étude, cinq classes de l'occupation et l'utilisation des sols ont été définies : constructions, forêt, routes, terres cultivables et sols nus.

IV.1.7.2. Classification OBIA basée sur des classificateurs de Machine Learning

Avant d'exécuter l'étape de classification, l'algorithme de segmentation multirésolution a été appliqué aux trois images d'entrée pour générer des segments homogènes en utilisant eCognition Trimble Developer (10.0). La taille des objets est définie par un paramètre d'échelle

(dans cette étude, le paramètre d'échelle =30 pour les images Landsat-5 TM et 10 pour l'image Sentinel-2). Les indices de compacité et de forme sont fixés à 0.9 et 0.1, respectivement.

Par ailleurs, dans la communauté de la télédétection, les classificateurs de Machine Learning, notamment RF et SVM ont été largement utilisés pour la détection des changements de l'occupation du sol (Chen *et al.*, 2012 ; Halmy *et al.*, 2015 ; Wang *et al.*, 2020).

Dans cette étude, les algorithmes de Machine Learning ont été exécutés pour entraîner la classification par le biais de données d'échantillons d'entraînement générées précédemment. Deux classificateurs ont été appliqués à cette étape, RF et SVM.

Puis, une validation des classifications de l'occupation et l'utilisation des sols produites a été faite pour confirmer la précision des méthodes utilisées nécessaires à l'évaluations des changements de l'occupation du sol.

IV.1.7.3. Évaluations des changements de l'occupation du sol

Les classifications produites pour les années 1999, 2009 et 2020 ont été utilisées comme entités d'entrée pour l'évaluation des changements de l'occupation des sols. Cette étape a été exécutée à l'aide d'un module de calcul d'une matrice de transition implémenté dans Arc GIS.

Ce module est basé sur un processus stochastique qui attribue la probabilité de la transition des classes d'occupation des sols d'une classe à une autre (Sinha *et Kumar* 2013 ; Weng, 2002). Les changements de l'occupation du sol pour la zone étudiée ont été évalués sur deux périodes, 1999-2009 et 2009-2020. En même temps, une matrice de transition a été calculée pour les deux périodes en utilisant une combinaison de deux images classifiées. Une matrice de transition des surfaces a également été calculée en utilisant une matrice de probabilité. La transition de surface représente la surface totale (en cellule) prévue pour changer d'une classe de l'occupation des sols à une autre sur le nombre prescrit d'unités de temps (Wang *et al.*, 2020).

IV.1.8. Évaluation de la précision des classifications

Les évaluations de la précision visent à valider les résultats et à confirmer la stabilité de chaque classificateur appliqué dans la méthodologie proposée. Les précisions de classification obtenues ont été évaluées à l'aide de l'OA, de la précision de l'utilisateur (UA), de la précision du producteur (PA) et de l'indice de kappa, dérivés d'une matrice de confusion.

Il s'agit des mesures les plus courantes utilisées pour évaluer la précision de la classification de l'occupation du sol (Foody, 2002). OA représente la performance globale de l'algorithme de classification présenté par le rapport entre le nombre total de pixels correctement classés et le

nombre total de pixels pour l'investigation terrestre dans toutes les catégories. PA a été calculé en divisant le nombre de pixels correctement classés dans chaque classe d'occupation du sol par le nombre total de pixels dans cette ligne et cette colonne, ce qui fournit la précision de la classe individuelle, tandis que UA représente la probabilité qu'un pixel attribué à une classe donnée fasse partie de cette classe (Mazzia et *al.*, 2019).

Le processus d'évaluation de la performance des classifications obtenues a été effectué en utilisant l'ensemble des échantillons de validation.

- Pour l'approche pixel par pixel, l'évaluation des performances a été réalisée à l'aide de la bibliothèque OTB Orfeo ToolBox. Pour chaque classificateur, la classification obtenue ainsi que le fichier vectoriel des échantillons de validation sont les entités d'entrée pour l'exécution.
- Pour les approches OBIA et CNN-OBIA, l'exécution de l'étape de validation a été effectuée dans eCognition conformément aux règles définies dans le processus de classification. Notons que pour les modèles CNN, une évaluation initiale du modèle a été précédemment effectuée pour créer les couches précises à utiliser comme unités d'entrée dans la post-classification par OBIA. Ensuite, nous avons évalué la classification obtenue après la post-classification.

IV.2. Résultats et discussion

IV.2.1. Synergie des données optiques et radar pour la cartographie de l'occupation du sol de la ville côtière Ain Témouchent par méthodes de Machine Learning

IV.2.1.1. Résultats de classification de l'occupation du sol

Les résultats d'analyse de l'occupation du sol sont issus de l'application de deux approches de classification, pixel par pixel et orientée objet. Les algorithmes RF et SVM ont été appliqués sur une série temporelle d'images fusionnées de Sentinel-1 et Sentinel-2.

Les valeurs des paramètres des algorithmes (RF et SVM) fixés après le processus d'optimisation, ainsi que les valeurs des paramètres de l'algorithme de segmentation ont été utilisées pour établir les cartes finales de l'occupation du sol par les deux approches. Les résultats sont illustrés en sous ensemble de classifications dans les figures IV.13, IV.14 et IV.15. Pour la classification pixel par pixel et pour les deux algorithmes RF et SVM, toutes les classes de l'occupation du sol définies lors de la sélection des échantillons (eau, sols nus, terres agricoles, constructions, végétation) sont apparues sur les cartes résultantes.

En effet, les surfaces en eau ont été très bien classées (indice de précision de 100 %) pour RF et SVM, à l'instar du barrage de Ain Tolba situé au sud-ouest de la ville d'Ain Témouchent. Néanmoins, il y avait des erreurs de classification pour certaines classes, où une confusion avec d'autres classes a été commise, notamment pour les classes : constructions, végétation et terres agricoles.

Les résultats obtenus pour les algorithmes de classifications RF et SVM pour l'approche pixel par pixel ont atteint respectivement 92,3 % et 90,1 % des précisions globales (OA) et 0,90 et 0,89 d'indices Kappa. Par conséquent, en comparant les deux algorithmes, le RF produit les meilleurs résultats.

Pour la classification OBIA, les résultats sont beaucoup plus satisfaisants avec une bonne apparition des classes sur la carte finale de l'occupation du sol. Les surfaces d'eau ont été très bien classées avec un indice de précision de 100 %. Ainsi, les Indices OA sont de l'ordre de 96 % et plus pour les classes constructions et sols nus, et de 95 % pour les terres agricoles.

Par ailleurs, les résultats obtenus pour les deux algorithmes de classifications RF et SVM pour la méthode OBIA ont atteint respectivement les valeurs 96,8 % et 92,0 % de OA et 0,95 et 0,90 d'indices Kappa.

En revanche, quelques erreurs de classification ont été commises pour la végétation, où des confusions entre cette classe et celles des terres agricoles et bâti ont été notées.

Ceci explique la faible valeur de l'indice de précision (45,3 %), relative à la classe de végétation. Cette valeur a été obtenue par la classification pixel par le classificateur RF. Le tableau IV.4 présente les résultats de calcul des indices de performance qui sont ; l'indice kappa, l'indice de précision produit (PA), l'indice de précision de commission (UA) et indice de précision globale (OA), calculés à partir de la matrice de confusion. Ces résultats sont obtenus pour les deux approches en appliquant deux algorithmes de Machine Learning RF et SVM. Globalement les résultats révèlent une bonne pertinence de la méthode OBIA.

L'indice kappa avec sa valeur 0,95 signifie que 95 % de la classification résultante ne sont pas dus au hasard. Ce qui confirme que les valeurs dans la matrice de confusion avaient une forte probabilité d'être correctes.

Tableau IV.4. Résultats Précision globale (OA) et coefficient kappa de RF et SVM appliqués pour les deux approches : pixel et OBIA.

Classe	Métriques (%)	RF_Pixel	SVM_Pixel	RF_OBIA	SVM_OBIA
Eau	PA	100	100	100	100
	UA			100	100
Sols nus	PA	93,1	89,1	88,5	97,1
	UA			99,5	96,9
Terres agricoles	PA	96,4	100	98,9	86,6
	UA			90,8	97,7
Constructions	PA	93,2	76,5	97,0	96,4
	UA			97,0	99,8
Végétation	PA	45,3	97,5	85,9	94,4
	UA			85,1	63,8
Overall accuracy (%)		92,3	91,0	96,8	92,0
Kappa		0,90	0,89	0,95	0,90




Figure IV.13. Sous ensemble 1 (Ain Témouchent centre) de la carte d'occupation du sol à partir de l'image fusionnée optique/radar.




Figure IV.14. Sous ensemble 2 (Ain Témouchent centre) de la carte d'occupation du sol à partir de l'image fusionnée optique et radar.

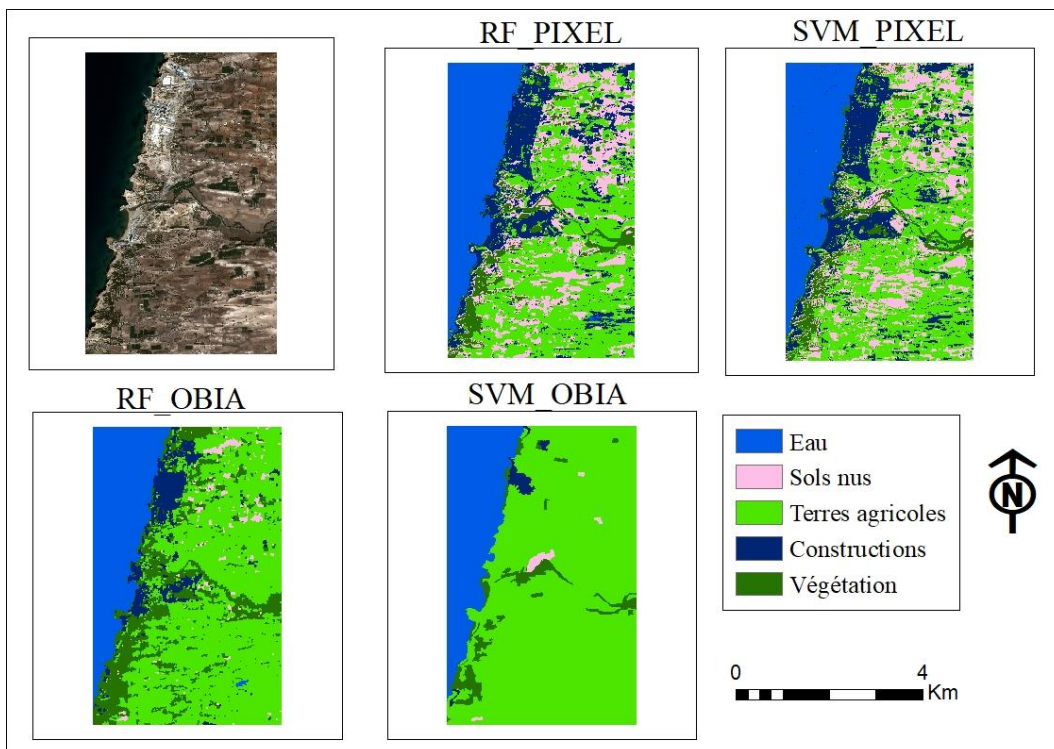


Figure IV.15. Sous ensemble 3 (région côtière d'Ain Témouchent) de la carte d'occupation du sol à partir de l'image fusionnée optique/radar.

IV.2.1.2. Contribution de la synergie optique radar pour la classification de l'occupation du sol

Dans cette étude, une série temporelle d'images fusionnées, optiques (Sentinel-2) et radar (Sentinel-1) a été analysée afin de modéliser l'occupation du sol dans une zone exposée aux risques d'inondation.

Cette synergie de produits multi-capteurs et multi-temporels offre une grande richesse spectrale, en effet, son analyse s'avère plus performante par rapport à une analyse des images d'une date unique (Gomez *et al.*, 2016 ; Tong *et al.*, 2013).

La fusion des bandes de NDVI et NDWI calculées augmente l'accès aux informations qui existent sur le terrain. L'indice de végétation s'avère stable pour détecter la végétation (Huete *et al.*, 2002). De même, l'indice de la teneur en eau NDWI, est efficace pour faire ressortir des informations relatives à l'humidité des sols ou de la végétation. Par conséquent, la fusion de toutes ces informations avec les images SAR vise à optimiser les avantages des deux capteurs pour améliorer l'analyse de l'occupation du sol.

IV.2.1.3. Contribution des approches Machine Learning

Les deux approches de classification, OBIA et pixel par pixel, ont montré leurs potentiels pour l'analyse de l'occupation du sol sur le terrain d'étude. L'interprétation des cartes résultant de la démarche suivie pour la classification, montre une représentation raisonnablement précise de l'occupation du sol.

En comparant les deux approches utilisées, il est évident que les résultats obtenus par l'approche OBIA (avec un OA de 96,9 %) sont meilleurs que ceux obtenus par pixel par pixel (un OA de 92,2 %). Dans cette optique, nombreuses études ont affirmé la pertinence et la précision de classification par cette approche, appliquée aux produits (HRS) (Belgiu *et Csillik.*, 2018).

Néanmoins, il a été constaté dans cette étude l'influence de l'algorithme de segmentation sur la classification finale pour l'approche orientée objet, où, la segmentation effectuée par l'algorithme multirésolution révèle plus de précision (96,8 %) avec des valeurs optimisées de l'algorithme Multi-resolution, et cela est expliqué par la stabilité et l'importance des paramètres de cet l'algorithme.

Ces paramètres prennent en considération plusieurs caractéristiques d'objets de l'image, à savoir, la résolution spectrale et spatiale, la forme, la texture, la couleur ... etc.

Par ailleurs, au niveau des algorithmes de Machine Learning utilisés, le RF a offert une analyse de haute précision de l'occupation du sol avec un calcul beaucoup plus rapide comparé au SVM,

et cela a été confirmé dans de nombreuses études, par exemple (Htitiou, et *al.*, 2019 ; Niculescu, et *al.*, 2018 ; Inglada, et *al.*, 2016). Cet algorithme nécessite peu de paramétrage (seulement deux paramètres, Ntree et Mtry), ce qui est considéré comme un avantage permettant d’optimiser le temps d’exécution.

De même, il peut traiter des données catégorielles et même des données avec des valeurs manquantes (Pal, 2005). Le processus d’optimisation par ‘cross-validation’, préconisé lors de ce travail, a contribué vivement à la production des cartes d’occupation du sol avec une meilleure précision. Les résultats d’optimisation des valeurs des paramètres Ntree et Ntry de l’algorithme RF à partir de l’image fusionnée optique/radar pour les méthodes OBIA et pixel par pixel ainsi que les précisions par classe sont illustrés dans les figures IV.16, IV.17 et IV.18.




Figure IV.16. Résultats d’optimisation des valeurs de paramètre Ntree de l’algorithme RF à partir de l’image fusionnée optique/radar pour les méthodes OBIA et pixel par pixel.

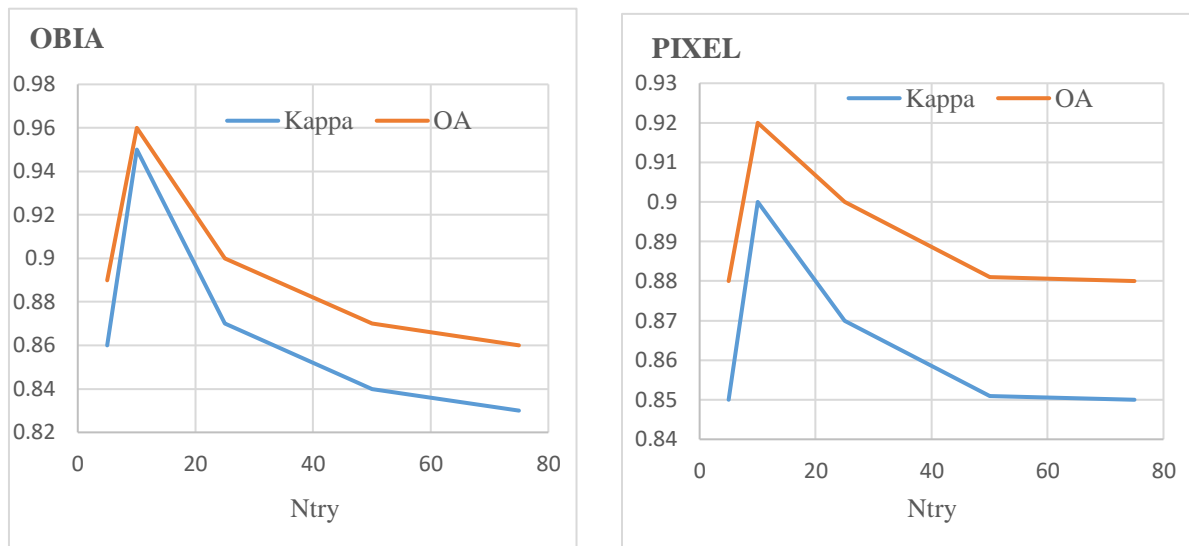


Figure IV.17. Résultats d'optimisation des valeurs de paramètre Ntry de l'algorithme RF à partir de l'image fusionnée optique/radar pour les méthodes OBIA et pixel par pixel.




Figure IV.18. Précisions par classe des classifications produites par les méthodes Pixel et OBIA.

En effet, la résolution spatiale des images Sentinel a permis de détecter cinq classes de types d'occupation du sol. Selon différentes études, il existe trois niveaux de détection de classes adaptées à l'évaluation de la vulnérabilité aux risques d'inondation. Les classes qui ont pu être détectées en utilisant les produits multicapteurs de Sentinel appartiennent au niveau 2, dont la

nomenclature adaptée au contexte d'étude des risques d'inondation comprend : l'urbain, les zones agricoles, les zones naturelles et les infrastructures de grande taille.

Ce niveau 2 est une caractérisation spatialement fine et sémantiquement détaillée (Puech et *al*, 2003). L'urbain et les infrastructures ont été détectés via la classe constructions, alors que les zones naturelles ont été représentées par les classes végétation, sols nus et eau.

Le niveau 2 correspond à des procédures propices aux interventions de gestion du risque d'inondation au niveau régionale, à l'instar des types de planification spatiale dans le cadre d'élaboration de Plan Directeur d'Aménagement de l'Urbanisme (PDAU). L'analyse de l'occupation du sol entreprise ici pourrait être considérée comme un outil de gestion dans ce cadre.

Dans le cadre de l'établissement du PPRI, l'analyse du type de l'occupation du sol nécessite une détection plus détaillée en allant jusqu'au niveau supérieur (niveau 3) qui comprend la connaissance des types de cultures et les types de constructions, à savoir les constructions publiques, les maisons individuelles, les constructions commerciales ...etc. Cette détection détaillée révèle à une représentation spatiale utile pour le contexte d'étude et des enjeux agissants dans les zones vulnérables au risque d'inondation. En effet, il est recommandé comme perspective à la clef de cette étude d'exploiter d'autres sources de données d'imagerie qui offrent une très haute résolution spatiale (THRS), comme par exemple les images Pléiades.

IV.2.2. Application des CNN combinés avec la méthode OBIA pour la cartographie de l'occupation du sol en zone côtière (Ain Témouchent)

Dans cette partie, nous présentons les résultats de l'application des réseaux de neurones convolutifs (CNN) combinés avec la méthode OBIA (Object Based Image Analysis) pour la cartographie de l'occupation et de l'utilisation du sol dans la ville côtière Ain Témouchent.

Les données satellitaires utilisées pour l'implémentation des méthodes proposées sont les images Pléiades et Sentinel-2. Par conséquent, les résultats de l'évaluation de la précision de toutes les méthodes utilisées et les cartes finales de l'occupation du sol pour chaque méthode des trois sous-ensembles de la zone d'étude sont présentés ici.

Ces trois sous-ensembles de classification ont été extraits afin d'améliorer les analyses visuelles, et incluent le centre d'Ain Témouchent en tant que zone urbaine, en plus de la zone côtière.

IV.2.2.1. Résultats de l'évaluation de la précision statistique

▪ Image Pléaïdes

Le tableau IV.5 montre les résultats de l'évaluation de la précision obtenus par les méthodes appliquées. La méthode basée sur le modèle profond CNN combinée avec OBIA a donné un OA de 93,5 % et un kappa de 0,91 pour les 10 catégories de l'occupation du sol de la zone d'étude. L'AO obtenu par cette méthode a ainsi montré une amélioration significative par rapport aux autres méthodes testées. En outre, RF-OBIA et SVM-OBIA ont obtenu des OA de 91,8 % et 88,2 %, ainsi que des kappas de 0,91 et 0,84; tandis que RF et SVM basés sur les pixels ont obtenu des OA de 84,8 % et 72,9 %, ainsi que des kappas de 0,83 et 0,70.

D'après les résultats de la méthode CNN-OBIA, les classes eau et routes ont atteint les UA les plus élevées (99,3 % et 97,7 %). En outre, la majorité des classes avaient des valeurs de l'indice de précision UA supérieures à 93 %, notamment les maisons agricoles, constructions, terres agricoles non cultivées et les sols nus.

Les terres agricoles cultivées ont été considérées comme les classes les plus mauvaises en termes de UA (moyenne ~ 80,8 %). Cela est fortement dû au chevauchement des valeurs de réflectance des pixels et de confusion avec certaines classes. Cependant, chacune de ces dernières classes a été détectée avec une UA de 68 % et 90,8 %. De plus, quelques confusions ont été observées entre les classes : routes et constructions, qui ont été classés avec des UA de 97,7 % et 95,1 %.

Considérant les méthodes peu profondes basées sur les algorithmes de Machine Learning RF/SVM, les valeurs de OA étaient généralement satisfaisantes. Les résultats démontrent que le OA obtenu par les algorithmes RF et SVM à travers OBIA ont surpassé les RF et SVM basés sur les pixels, produisant une différence de 7 % (84,8 % - 91,8 %).

Les meilleurs résultats en termes de OA fournis par les méthodes OBIA sont ceux obtenus avec le RF, atteignant un OA de 91,8 % et un kappa de 0,85. Par ailleurs, le SVM a obtenu un OA de 88,2 % et un kappa de 0,84. En outre, les mêmes tendances ont été observées lors de la comparaison des algorithmes basés sur les pixels, où la RF a obtenu un OA de 84,8 % et un kappa de 0,83, tandis que le SVM a obtenu un OA de 72,9 % et un kappa de 0,70. Les classes de l'occupation du sol les plus efficacement détectées par la RF étaient l'eau et les stades, avec des OA de 99,6 % et 99,3 % (tableau IV.5).

En revanche, les terres agricoles cultivées et les sols nus étaient les plus mal classées, avec des UA de 68 % et 67,4 %. Concernant l’algorithme RF qui est basé sur les pixels, les classes eau et sols nus ont été bien classées, avec des UA de 100 % et de 95,9 %.

Cependant, les constructions et les forêts ont été les moins précises en termes de UA (67,9 % et 77,5 %). En outre, une confusion subsistait entre les constructions et les routes, et entre les classes forêts et terres agricoles cultivées, en raison de la réflectance des pixels.

Tableau IV.5. Résultats d’évaluation de la précision de la classification de l’occupation du sol à partir de l’imagerie Pléiades.

Classe	Métriques (%)	RF_	SVM_	RF_	SVM_	OB_
		Pixel	Pixel	OBIA	OBIA	CNN
Eau	PA	98,5	97,7	97,4	95,1	99,3
	UA	100	97,7	99,6	99,1	99,4
Terres agricoles	PA	91,1	73,0	92,4	89,5	91,2
	UA	85,6	88,9	68,03	68,3	70,9
Maisons vertes	PA	84,3	91,2	91,9	92,9	89,5
	UA	89,7	47,1	92,7	73,3	94,3
Constructions	PA	75,2	82,5	84,7	80,8	96,2
	UA	67,9	59,7	98,7	87,2	95,1
Jachère	PA	79,6	45,8	92,01	86,91	93,9
	UA	95,6	78,4	96,2	96,1	95,2
Sols nus	PA	92,4	81,3	88,7	90,5	89,2
	UA	95,9	28,5	67,4	53,2	94,3
Routes	PA	88,7	73,6	88,4	86,6	91,3
	UA	86,8	87,4	94,4	92,7	97,7
Terres non agricoles	PA	88,3	69,30	84,7	79,6	90,8
	UA	87,4	88,1	98,7	98,8	97,6
Forêts	PA	71,8	72,8	76,0	82,2	93,1
	UA	77,5	45,5	92,0	94,3	90,8
Stades	PA	95,2	97,7	94,0	92,2	49,9
	UA	95,4	100	97,3	88,9	96,1

▪ Image Sentinel-2

Les résultats obtenus pour les données de Sentinel-2 sont présentés dans le tableau IV.6. Le modèle CNN combiné avec OBIA et les autres méthodes testées basées sur RF et SVM ont obtenu des résultats satisfaisants, avec des OA allant de 77,4 à 91 %.

En outre, dans ce cas, OBIA basée sur la RF a produit les meilleurs résultats, avec un OA de 91 % comparé avec le modèle CNN (83,4 %). Cela peut probablement s'expliquer par l'effet de la résolution spatiale dans le processus de classification. De plus, dans les deux méthodes, les classes : eau et constructions ont été bien classées, avec des UA de 100 % et 99,9 % achevées par la méthode CNN-OBIA et de 98,9 % et 98,0 % par OBIA basée sur le classificateur RF.

Pour la méthode basée sur les pixels, les classes eau et constructions ont été bien détectées, avec des UA de 98,1 % et 73,0 %, avec l'algorithme RF. Pour les deux classificateurs, les forêts ont été mal classées, avec des UA < 35 % avec RF et < 47 % avec SVM.

En ce qui concerne les méthodes peu profondes de Machine Learning, les résultats obtenus avec RF étaient largement supérieurs à ceux obtenus avec SVM pour les méthodes OBIA et pixel. RF-OBIA et SVM-OBIA ont atteint 91 % et 72 %, tandis que RF-Pixel et SVM-Pixel ont atteint 80,1 % et 77,4 % ; ainsi, RF a surpassé SVM quelle que soit la méthode implémentée.

Tableau IV.6. Résultats d'évaluation de la précision de la classification de l'occupation du sol à partir de l'image Sentinel-2.

Classe	Métriques (%)	RF_Pixel	SVM_Pixel	RF_OBIA	SVM_OBIA	OB_CNN
Eau	PA	97,2	95,5	96,5	98,3	100
	UA	98,1	100	98,9	96,7	100
Sols nus	PA	60,1	66,2	98,7	63,3	99,6
	UA	64,0	84,0	94,8	90,8	82,6
Terres agricoles	PA	71,1	70,1	98,0	47,9	82,6
	UA	50,5	99	85,0	75,1	84,1
Constructions	PA	84,0	78,0	89,0	83,6	65,5
	UA	73,0	75,0	98,0	67,4	99,9
Terres non agricoles	PA	72,0	98,9	98,9	84,4	83,3
	UA	46,4	47,0	96,6	64,0	77,7
Forêts	PA	52,2	99,0	96,6	86,2	74,7
	UA	32,2	46,0	98,9	26,6	63,3

Par ailleurs, les résultats obtenus pour les deux types de données satellitaires utilisés à l'entrée dans le processus de classification ont été également comparés. En termes de OA, les données Pléiades ont fourni de meilleurs résultats que celles de Sentinel-2 à travers toutes les méthodes testées, y compris la méthode CNN-OBIA proposée qui a obtenu les meilleurs résultats par rapport aux autres méthodes, avec une différence de 2,5 % comparée à RF-OBIA obtenue à

partir de Sentinel-2. De même, la classification à l'aide des méthodes de Machine Learning basées sur RF et SVM a abouti des résultats relativement satisfaisants, avec des différences de 0,8 % et 16,2 % . Pour la méthode basée sur les pixels, les classifications obtenues par les images Pléiades ont surpassé Sentinel-2 de 4,7 % pour l'algorithme RF, et de 4,5 % pour SVM. Les OA et kappa obtenus à travers toutes les méthodes sont présentés dans le tableau IV.7.

Tableau IV.7. Les précisions globales (OA) obtenues et kappa avec les images Pléiades et sentinel-2.

Image d'entrée	Modèle	OA (%)	kappa
Pléiades	RF_Pixel	84,8	0,83
	SVM_Pixel	72,9	0,70
	RF_OBIA	91,8	0,85
	SVM_OBIA	88,2	0,84
	OB_CNN	93,5	0,91
Sentinel-2A	RF_Pixel	80,1	0,71
	SVM_Pixel	77,4	0,69
	RF_OBIA	91,0	0,87
	SVM_OBIA	72,0	0,70
	OB_CNN	83,4	0,80

IV.2.2.2. Résultats de cartographie de l'occupation du sol à partir des données Pléiades et Sentinel-2

Les figures IV.19-21 présentent les résultats des méthodes de classification à partir de l'image Pléiades. L'examen visuel des cartes d'occupation du sol produites a montré que les 10 catégories définies ont été détectées à travers toutes les méthodes, bien qu'un certain nombre de différences aient été observées.

Ainsi, la méthode CNN-OBIA s'est avérée la plus appropriée pour la détection des classes et leurs limites à haut niveau. En particulier, les constructions, les terres agricoles, les routes et les stades ont été bien délimités. En ce qui concerne les autres méthodes, quelques confusions ont été observées dans les cartes dérivées, notamment entre les routes et les constructions, ainsi qu'entre les forêts et les terres agricoles.

En revanche, les cartes produites par la classification RF-Pixel et SVM-Pixel ont présenté de mauvaises classifications. En dépit de cette constatation, à travers ces méthodes et la méthode CNN-OBIA, les zones de constructions ont été bien détectées en comparant aux méthodes

OBIA seulement, comme le confirme la zone côtière (figure IV.21), où CNN a délimité avec précision le port et les sols nus (ici, les plages).

Par ailleurs, les constructions côtières ont été mal classées par les méthodes OBIA et d'analyse basée sur les pixels. Des résultats similaires ont été observés pour les terres cultivées (figures IV.19 et IV.20), CNN étant capable de distinguer les terres cultivées des forêts, tandis que la majorité des zones agricoles étaient également bien délimitées. En comparant les classificateurs pour chaque méthode de Machine Learning, une légère différence de classification a été observée entre RF et SVM. En général, il y avait une confusion dans la distinction entre les routes et les constructions dans les cartes finales de l'occupation du sol.

Dans la carte SVM-pixel, les forêts ont été mal classées, étant confondues avec les terres cultivées et les jachères.

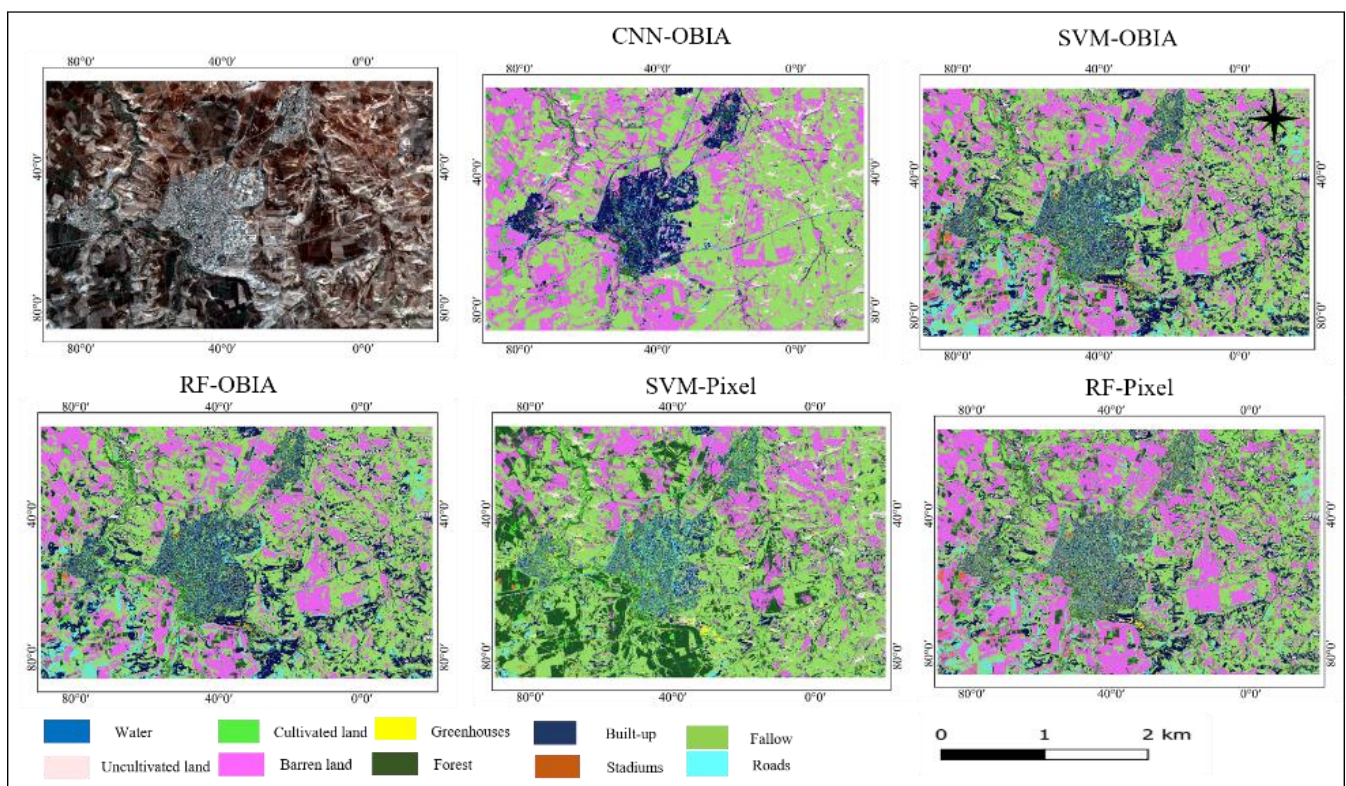


Figure IV.19. Sous ensemble 1 (Ain Témouchent centre) de la carte d'occupation du sol à partir de l'image Pléiades.




Figure IV.20. Sous ensemble 2 (Ain Témouchent centre) de la carte d'occupation du sol à partir de l'image Pléiades.




Figure IV.21. Sous ensemble 3 (région côtière d'Ain Témouchent) de la carte d'occupation du sol à partir de l'image Pléiades.

Les figures IV.22- 24 présentent les résultats de classification des différentes méthodes fournies pour l'image Sentinel-2A. Les six catégories ont été détectées avec toutes les méthodes implémentées, bien qu'il y ait un certain nombre de différences remarquables dans les cartes de l'occupation du sol finales.

Pour la méthode basée sur le CNN combiné avec OBIA, les constructions, les terres non agricoles et les terres agricoles ont été bien détectées et délimitées. La classification CNN a donné des résultats similaires à la méthode RF-OBIA (Figure. IV.22). De même, les terres non agricoles ont été bien identifiées, bien qu'avec une confusion limitée.

Dans la méthode d'apprentissage SVM, une confusion entre les terres agricoles et les forêts, ainsi qu'entre les terres non agricoles et les zones de constructions ont été observées, aboutissant à une mauvaise classification (figure IV.24). Par ailleurs, les routes, incluses dans les constructions ont également été bien délimitées par la majorité des méthodes. Les comparaisons des cartes finales fournies par les données Sentinel-2A et les données Pléiades ont montré que les cartes de l'occupation du sol basées sur ces dernières étaient de meilleure qualité en termes de délimitation de chaque catégorie prédéfinie, en raison des effets de la résolution spatiale affectant le processus de classification et la précision visuelle des cartes produites.




Figure IV.22. Sous ensemble 1 (Ain Témouchent centre) de la carte d'occupation du sol à partir de l'image Sentinel-2.

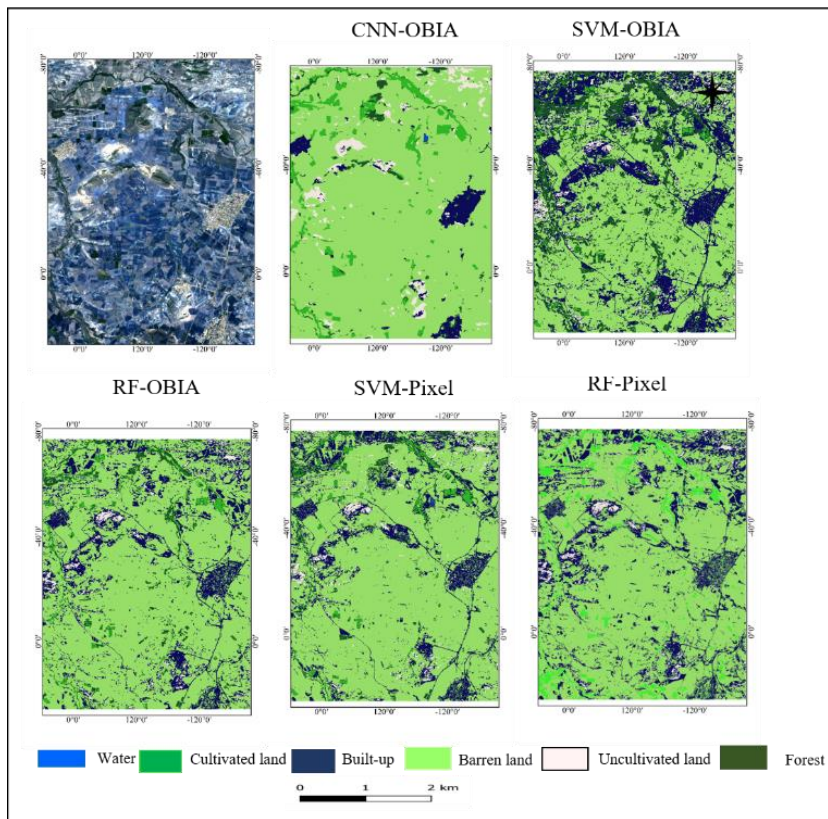


Figure IV.23. Sous ensemble 2 (Ain Témouchent centre) de la carte d'occupation du sol à partir de l'image Sentinel-2.




Figure IV.24. Sous ensemble 3 (région côtière d'Ain Témouchent) de la carte d'occupation du sol à partir de l'image Sentinel-2.

IV.2.2.3. Discussion des résultats

Bien que l'application de méthodes de Machine Learning pour la cartographie de l'occupation du sol, en particulier la classification basée sur l'OBIA, ait donné de bons résultats dans plusieurs études (Amini et *al.*, 2018 ; Blaschke, 2010), ces méthodes souffrent de problèmes liés à des erreurs de classification, dues en partie à l'hétérogénéité des classes d'occupation du sol et à la similarité de leurs signatures spectrales.

Par conséquent, une technique d'extraction avec un niveau plus élevé de caractéristiques a été fortement recommandée pour l'extraction plus précise des composantes de l'occupation du sol. Dans ce sens, l'utilisation des CNNs a démontré une grande capacité pour la cartographie de l'occupation du sol.

Plusieurs études basées sur des modèles CNN ont analysé la question de la détection de l'occupation du sol, en particulier dans les zones côtières, à l'instar, (Ienco et *al.*, 2019 ; Liu et *al.*, 2019). Les résultats expérimentaux de ces études ont démontré un potentiel élevé dans la détection de l'occupation du sol, et des améliorations de la précision dans la classification >90 % de OA.

Néanmoins, les performances élevées des modèles CNN traditionnels dans la classification de l'occupation du sol, les analyses sont effectuées au niveau du pixel, ce qui peut entraîner des erreurs de classification dues à la distribution spatiale des classes, en plus du grand nombre de couches CNN créées pour effectuer la classification. Par conséquent, la méthode intégrant le concept d'objets (OBIA) avec les CNNs peut remédier à ces limitations en classifiant les images par le biais d'objets segmentés et extraire les caractéristiques générées automatiquement avec une précision de haut niveau à travers un modèle CNN.

Dans la présente étude, un modèle d'apprentissage profond CNN combiné à une méthode OBIA a été utilisé pour extraire les caractéristiques de l'occupation du sol à Ain Témouchent, en Algérie. La méthodologie proposée intègre le CNN avec la classification OBIA pour l'extraction des caractéristiques. Ce processus de classification a été réalisé sur deux types d'imagerie satellitaire : les données Sentinel-2 et Pléiades, acquises le même jour en octobre 2020. En plus de la méthode CNN profonde intégrée à OBIA, deux autres méthodes (pixel par pixel et OBIA) basées sur des algorithmes de Machine Learning (RF/SVM) ont également été testées sur les deux ensembles de données, afin de comparer les capacités des méthodes proposées basées sur CNN. En outre, un modèle CNN optimisé et OBIA ont été utilisés pour améliorer la précision de la classification et produire des cartes d'occupation du sol avec une

grande précision. Pour l'image Pléiades, deux couches primaires (convolutions et couches de max-pooling) ont été adoptées comme architecture CNN, avec une taille d'échantillon patches d'entrée de 16×16 pixels.

Les paramètres CNN (par exemple, la taille du patch d'échantillon, les couches cachées et le taux d'apprentissage) ont été optimisés sur la base de méthodes de validation croisée pour obtenir l'architecture finale avec une précision optimale. Le même processus a été appliqué à l'imagerie Sentinel-2, mais une seule couche cachée avec des couches de convolution et de mise en commun maximale (max-pooling) a été incorporée, avec une taille d'échantillon d'entrée de 32×32 pixels.

Ces paramètres notamment la taille de l'échantillon, ont eu un impact significatif sur la précision de la classification. Pour cette raison, une seule couche cachée a été générée pour obtenir un résultat optimal pour Sentinel-2. Contrairement aux données des Pléiades, les résultats optimaux d'OA ont été obtenus en générant deux couches cachées.

De même, selon des études précédentes, la taille des échantillons patches affecte la précision de modèle CNN, et a également une influence significative sur les résultats de précisions globale des classifications obtenues. En effet, un certain nombre de tailles testées ont produit des classifications inexactes, tandis que d'autres ont produit les classifications optimales en termes de OA. La figure IV.25 montre les résultats des valeurs de taille de patches testées pour les deux ensembles de données utilisés pour la construction du CNN.




Figure IV.25. Effet de la taille de l'échantillon patch de CNN sur OA.

Les graphiques montrent l'influence de la taille des patchs sur la précision OA. Pour les données des Pléiades, les patchs de grande taille (64×64) et de petite taille (8×8) ont produit des classifications inexactes. Les mêmes constatations ont été observées pour les données Sentinel-2A. De plus Il est à noter que, la génération d'un modèle CNN avec une grande taille de patch nécessite de forte puissance de calcul, de matériel et de temps.

Dans l'ensemble, le travail effectué ici a mis en évidence les avantages d'une architecture CNN simple par rapport à d'autres études qui ont utilisé des couches multiples et des patchs de grande taille (Ienco et *al.*, 2019 ; Mahdianpari et *al.*, 2018). Par exemple, (Zhao et *al.*, 2017) ont évalué les effets de la profondeur de l'architecture CNN sur l'apprentissage de l'extraction profonde, en construisant des modèles CNN avec 1 à 5 profondeurs différentes pour évaluer les impacts correspondants. Les résultats ont confirmé que les architectures CNN plus profondes produisaient les précisions de classification les plus élevées ($\leq 95\%$) ; cependant, la génération de ces modèles nécessite beaucoup plus de temps et de puissance de calcul.

En comparant ces résultats à ceux révélés ici, des résultats tout aussi précis ($OA \geq 93\%$) ont été obtenus en passant par une architecture CNN simple à deux couches cachées. Les résultats obtenus confirment que la taille d'échantillons des patchs d'entrée pour les modèles CNN pouvait affecter de manière significative la classification (Ghorbanzadeh et *al.*, 2021).

Par une méthode d'optimisation, la taille du patch optimal a été fixée à 20×20 pour un processus de classification basée sur le CNN combinée avec OBIA. Les résultats confirment qu'en plus de la capacité du CNN, l'OBIA par le biais de la segmentation Multi-resolution pourrait fortement influencer la classification et par conséquent les résultats des précisions globales.

Dans cette même optique, malgré la capacité de la sélection d'une architecture approprié de CNN et ses caractéristiques en tant qu'entité d'entrée OBIA, il est primordial de prendre en considération l'influence des paramètres de la segmentation, notamment d'échelle, sur les processus de segmentation.

Notons que les valeurs d'OA ont été affectées par le paramètre d'échelle (figure IV.26). Cela a également été observé dans d'autres études, par exemple, (Liu et *al.*, 2019 ; Zhao et *al.*, 2017). Dans cette situation, les paramètres de forme et de compacité ont été fixés aux valeurs par défaut de 0,1 et 0,5.

Ce paramètre clé est celui qui contrôle la taille des objets segmentés, ajustant ainsi le niveau de détail souhaité ; par conséquent, l'optimisation de ce paramètre est une étape essentielle pour obtenir des résultats de classification optimaux. Dans ce cas, la valeur optimale de ce paramètre était 15 pour la méthode OBIA basée sur CNN et les autres méthodes de Machine Learning pour les deux images d'entrée.




Figure IV.26. Effet du paramètre d'échelle de segmentation sur OA.

D'une manière générale, le CNN combiné à l'OBIA a amélioré de manière significative la classification de l'OA de 1,7 % par rapport à ce que RF-OBIA a obtenu lors de l'évaluation de l'image VHR Pléiades. Les résultats obtenus ont donc démontré l'efficacité du CNN en tant que classificateur, et son potentiel à identifier les limites des catégories de l'occupation du sol. Cela confirme son utilité pour la classification de l'occupation du sol, en particulier, dans des environnements à grande échelle. Pour l'image Sentinel-2, la compétition était remarquable entre CNN et RF exécuté au niveau d'objets (avec OBIA). Le classificateur RF a obtenu les meilleurs résultats, avec un OA > 7 % plus grand comparé à CNN.

Pour les méthodes de Machine Learning, les résultats de la classification ont montré que l'OBIA a superposé d'une manière significative les analyses effectuées par la méthode pixel par pixel pour les deux ensembles de données. Ces résultats sont conformes aux autres études de cartographie de l'occupation du sol, par exemple, (Duro et al., 2012 ; Myint et al., 2011). Inversement, en comparant les classificateurs de Machine Learning (RF et SVM), les deux ont obtenu de bons résultats, avec des OA > 70 %.

En ce qui concerne les cartes d'occupation du sol, les méthodes proposées ont permis d'extraire des caractéristiques d'occupation du sol avec une grande précision dans la zone étudiée, où presque toutes les classes d'occupation du sol ont été bien distinguées.

Pour la classification basée sur l'image Pléiades (figures. IV.19-21), la méthode CNN-OBIA a permis de détecter toutes les classes d'occupation du sol définies : eau, terres agricoles, sols nus, constructions, jachères, terres non agricoles, routes, maisons vertes, forêts et stades. De plus, la distinction entre les classes a été bien illustrée, les constructions étant particulièrement bien distinguées des routes.

En dépit de la similitude de la réflectance des pixels entre les forêts et les terres agricoles, les deux classes ont été bien extraites. Pour les analyses de l'image Sentinel-2 (figures IV.22-24), les catégories : eau, terres agricoles, terres non agricoles, constructions, sols nus et forêts ont également été bien délimitées à l'aide des méthodes proposées et de Machine Learning.

Cependant, les cartes de l'occupation du sol dérivées de la méthode proposée et l'algorithme RF par OBIA étaient beaucoup plus similaires. Ainsi, en raison de diverses erreurs de classification, l'OBIA basée sur le CNN s'est avérée être la plus appropriée pour la détection des classes de l'occupation du sol dans le cas de Sentinel-2.

Notons que, dans ce cas, malgré une résolution spatiale affectant également le processus de classification, les classifications fournies par Pléiades avaient un niveau de détail spatial plus élevé que celles de Sentinel-2.

Dans un autre contexte, malgré la grande précision obtenue par les CNN combinés à l'OBIA par rapport aux méthodes de Machines Learning seules, ces dernières méthodes, en particulier celles basées sur le classificateur RF, étaient compétitives et ont obtenu de bons résultats dans la classification de l'occupation du sol. Comme mentionné dans quelques études précédentes (Htitiou et *al.*, 2019; Niculescu et *al.*, 2020), le RF a donné des résultats pertinents, comparé à SVM, quelles que soient les données satellitaires utilisées. Pour les Pléiades, le RF a surpassé le SVM de 11,9 % avec la méthode basée sur les pixels, et de 3,6 % en utilisant OBIA. De même, pour les données Sentinel-2, la classification RF a surpassé SVM avec une valeur de OA > 2,7 % pour l'analyse basée sur les pixels, et > 10 % pour la classification OBIA.

Dans ce sens, les paramètres RF ont également une influence significative sur l'apprentissage de la classification. C'est pourquoi, l'optimisation des paramètres RF, principalement le nombre total d'arbres, peut améliorer d'une manière typique les résultats de la classification. A partir

d'une validation croisée, un grand nombre d'arbres dans l'intervalle (50-500) ont été testés ici, et les OA ont été évalués pour chaque valeur. La figure IV.24 illustre l'impact du nombre d'arbres RF (*n_{tree}*) sur la précision OA pour la classification par OBIA et de la méthode basée sur les pixels, où on peut confirmer la forte influence de cet hyperparamètre sur la précision de la classification. L'évaluation de l'impact du paramètre *n_{tree}* a été effectuée en tenant compte les deux images d'entrée.

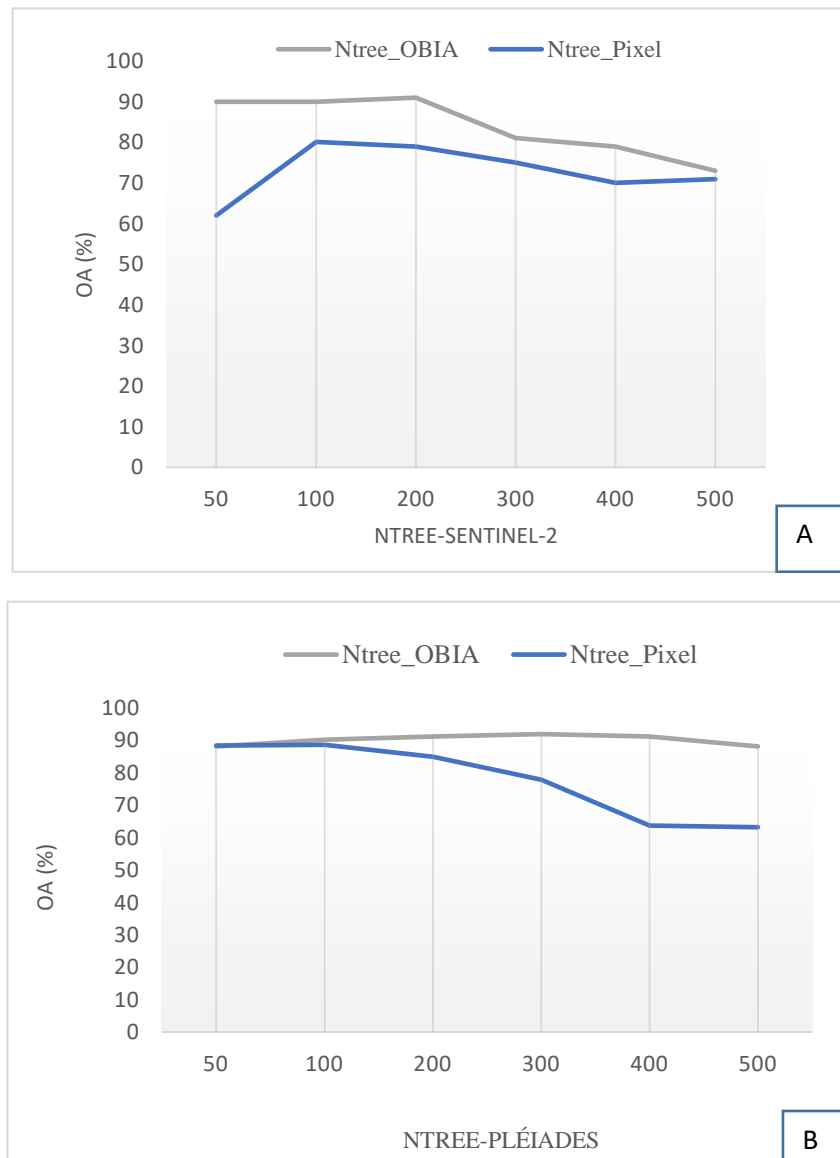


Figure IV.27. Effets du paramètre Ntree sur l'OA de la classification. A : effets sur les données Sentinel-2. B : effets sur les données Pléiades.

En fait, au sujet de cartographie de l'occupation du sol par les méthodes automatiques, cette étude démontre le potentiel du CNN pour la classification l'occupation du sol exécutée à niveau d'image segmentée à partir de données à haute et très haute résolution. Bien que ces modèles

d'apprentissage profond nécessitent plusieurs échantillons de données de haute qualité pour l'optimisation des algorithmes.

Les classes d'occupation du sol sont mieux identifiées en utilisant uniquement la sémantique plutôt que les images, ce qui se reflète dans les scores de précision et l'analyse qualitative. Une composante principale des CNN est la disponibilité de grandes données d'entraînement qui permettent un entraînement réussi du modèle.

Par conséquent, la performance est étudiée sous certains angles, notamment en examinant la performance globale des classifications et en discutant des précisions par classe. Il aborde également l'analyse qualitative et clarifie la façon dont la sémantique peut être utilisée comme source d'information dans la classification. En particulier, les classes de l'occupation du sol liées aux structures artificielles, telles que la classe constructions, ont une précision de classification plus élevée. Globalement, la méthode d'apprentissage profond proposée ici réussit à discriminer, à classer des classes très similaires sur la base d'informations spectrales, et à générer des cartes très précises.

Malgré la supériorité du modèle proposé, nous constatons que notre modèle d'apprentissage profond nécessite généralement plus d'échantillons d'entraînement que les méthodes de Machine Learning traditionnelles.

IV.2.3. Évaluation de la combinaison des (CNN) et la méthode OBIA pour la classification de l'occupation du sol à l'aide de l'imagerie satellitaire Sentinel-2 dans la région de Ténès

Cette section présente les résultats de l'évaluation de la méthode CNN combinée à la méthode OBIA pour la classification de l'occupation du sol dans la deuxième zone d'étude « Ténès ». La méthode proposée a été appliquée à l'imagerie satellitaire Sentinel-2 en exploitant ses caractéristiques spectrales.

L'objectif visé est de tester une approche simple et nouvelle dans la communauté de la télédétection intégrant un modèle de Deep Learning avec une approche de classification d'une image segmentée.

Toutefois, pour comparer les résultats de la classification avec cette approche, une approche OBIA a été appliquée simplement dans le logiciel eCognition avec deux algorithmes d'apprentissage automatique, à savoir RF et SVM. Dans l'étape de segmentation, un algorithme Multi-résolution a été mis en œuvre pour les deux approches afin de générer des segments à partir de l'image d'entrée.

Les catégories de couverture terrestre utilisées dans le processus de classification sont principalement : eau, construction, terres agricoles, forêt, végétation moyenne, routes, terres non agricoles et les sols nus.

De plus, une évaluation de la précision de la classification a été effectuée pour valider les résultats obtenus. En outre, une approche OBIA avec deux algorithmes de Machine Learning, SVM et RF, a été appliquée pour évaluer les performances de l'approche proposée par rapport aux méthodes conventionnelles de classification.

La précision de la classification a été évaluée par le biais de la matrice de confusion calculée à partir d'échantillons de validation. En fait, les principales métriques dérivées de la matrice de confusion sont : la précision globale (OA), l'indice Kappa, UA et PA.

IV.2.3.1. Composantes du modèle CNN construit

Le modèle CNN appliqué dans cette étude a été mis en œuvre par le biais du logiciel eCognition Developer 10.0. Trois étapes sont nécessaires pour créer ce modèle, essentiellement : la création, l'entraînement, et l'application du modèle.

Par conséquent, après un processus de validation croisée en testant plusieurs tailles de patches (8x8, 10x10, 16x16, 20x20, 32x32 et 64x64 pixels), le modèle CNN a été entraîné avec des patches d'une taille de 32x32 pixels. Les patches ont été échantillonnés de manière aléatoire sur l'image Sentinel-2. Pour chacune des 8 catégories de l'occupation du sol, 10 000 échantillons ont été sélectionnés. Par conséquent, $10\ 000 \times 5 = 50\ 000$ patches ont été générés. Le modèle CNN a été généré avec deux couches cachées.

Deux couches de convolutions ont été appliquées à la couche d'entrée avec différents noyaux de tailles de pixels 7×7 pixels et 3×3 pixels. Pour l'entraînement du modèle, le taux d'apprentissage a été fixé à 0,0015 après essais et erreurs. À l'issue de l'exécution du modèle CNN, 8 couches de caractéristiques entièrement connectées (Heatmaps) ont ensuite été générées. Ces couches correspondant aux classes d'occupation du sol déjà définies.

IV.2.3.2. Résultats de la classification de l'occupation du sol

En utilisant les couches entièrement connectées comme entité d'entrée pour la post classification, une approche OBIA a été appliquée à l'image satellite, en suivant une étape de segmentation multirésolution avec les valeurs de paramètres suivantes : échelle = 20, forme = 0,1 Compacité = 0,5 En conséquence, les résultats de la classification dérivés pour chaque approche sont rapportés dans les figure IV.28, IV.29 et IV.30.




Figure IV. 28. Classification d'occupation du sol par la méthode CNN-OBIA.

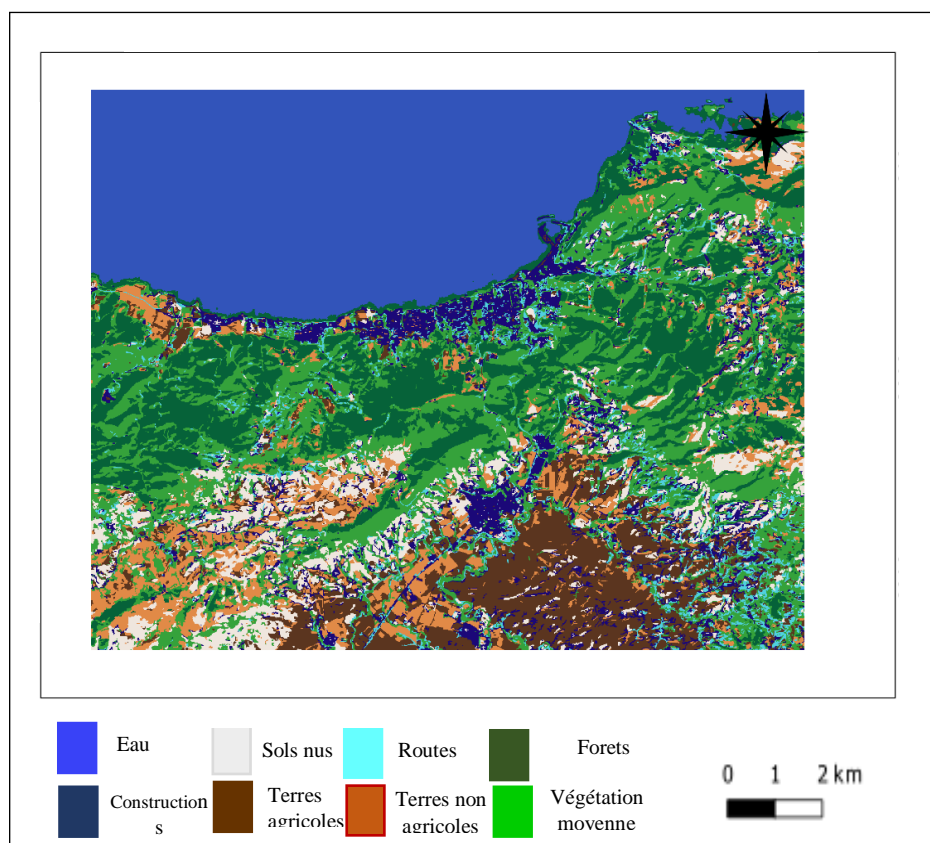


Figure IV. 29. Classification d'occupation du sol par le classificateur RF (OBIA)

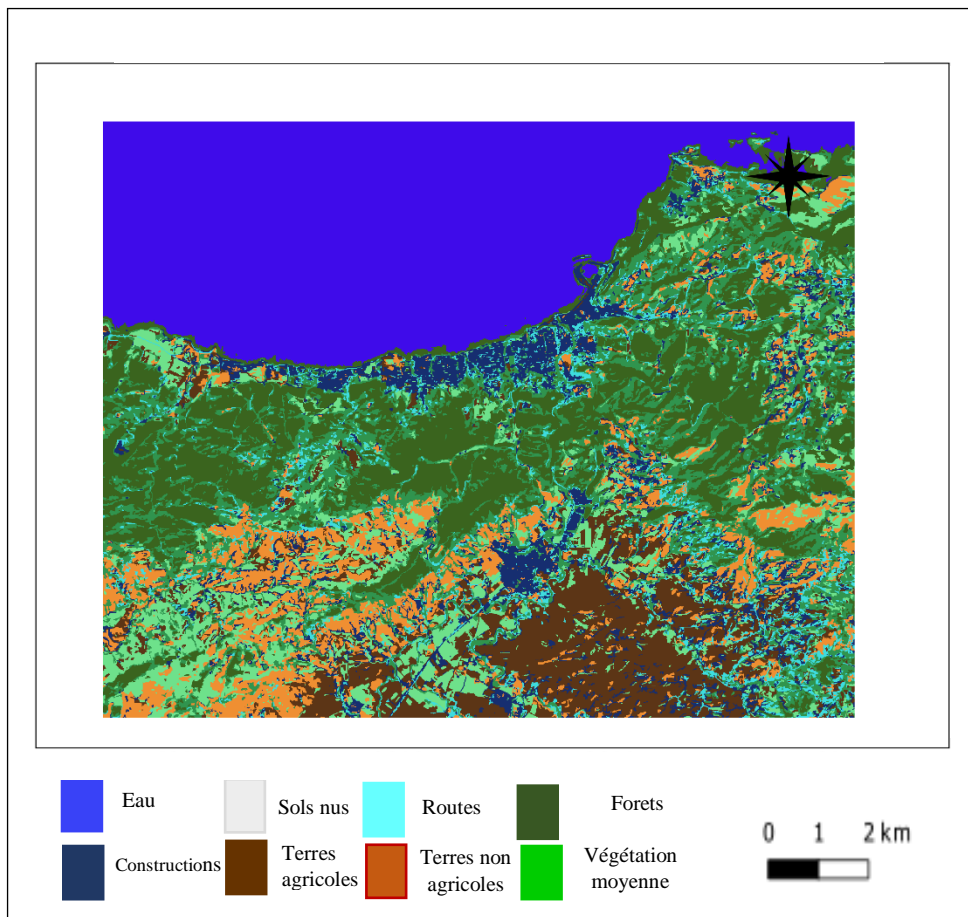


Figure IV.30. Classification d'occupation du sol par le classificateur SVM (OBIA).

L'examen visuel des cartes d'occupation du sol révèle une représentation raisonnable de la situation de l'occupation du sol de la zone étudiée. Par conséquent, toutes les catégories d'occupation du sol sont présentées dans les résultats de la classification finale. Cependant, l'approche proposée, qui combine un modèle CNN et la classification OBIA, montre des résultats très satisfaisants, où la précision globale (OA) et l'indice Kappa ont atteint les valeurs 93,1 % et 0,91, respectivement. En outre, concernant les précisions par classe obtenues, les valeurs des indices UA et PA ont également été satisfaisantes atteignant plus de 80 % pour la majorité des classes.

En plus, à travers cette méthode, les classes : constructions, forêts et eau ont été très bien détectées, avec des précisions UA de 96.5 %, 98.5 % et 100 %, respectivement. Pour les précisions PA obtenues, les classes : eau, terres agricoles et forêts, ont été très bien classées avec des valeurs de PA de 100 %, 100 % et 98.5 %.

En considérant les classificateurs de Machine Learning performés à travers l'approche OBIA, les résultats montrent que l'algorithme RF a surpassé l'algorithme SVM en termes de précision globale avec une différence atteignant 12 % de OA. En fait, la valeur OA a atteint 92,1 % pour l'algorithme RF et 79,6 % pour le SVM et une valeur de kappa de 0,90 pour RF et 0,74 pour SVM. En termes de précision par classe, l'eau (UA= 100 %), les terres agricoles (UA= 98,5 %) et les terres non agricoles (UA= 97,4 %), ont été très bien classées par RF-OBIA.

Par ailleurs, en comparant la méthode CNN-OBIA avec des méthodes basées sur des algorithmes d'apprentissage automatique, on remarque que l'approche CNN-OBIA est plus stable, avec une différence de précision OA de 0,3 % par rapport à OBIA performée avec le classificateur RF.

Les résultats de la précision globale, l'indice de Kappa, ainsi que les précisions par classes pour les méthodes implémentée dans l'étude sont rapportés dans le tableau IV.8.

Tableau IV.8. Résultats d'évaluation de la précision de la classification de l'occupation du sol à partir de l'image Sentinel-2.

Classes	CNN		OBIA _{SVM}		OBIA _{RF}	
	PA (%)	UA (%)	PA (%)	UA (%)	PA (%)	UA (%)
Eau	100	100	100	100	100	100
constructions	84,4	96,5	88,8	60,8	86,4	94,1
Terres agricoles	100	88,8	26,3	67,8	98,5	98,5
Forêts	98,5	98,5	99,6	93,4	96,6	90,4
Végétation moyenne	76,5	80,5	37,9	77,3	62,5	85,1
Routes	95,1	62,9	51,2	51,2	97,5	55,5
Terres non agricoles	96,6	90,4	15,9	82,3	97,4	97,4
Sols nus	97,4	94,4	100	91,0	98,2	92,1
OA (%)	93,1		79,6		92,2	
Kappa	0,91		0,74		0,90	

Dans cette application, une architecture de réseaux neuronaux convolutifs (CNN) combinée à une analyse d'image basée sur les objets (OBIA) a été proposée et expérimentée sur l'ensemble des combinaisons des informations spectrales de Sentinel-2. L'objectif est d'analyser, d'extraire et de distinguer les classes de l'occupation du sol. Les expériences ont été menées sur une ville côtière située dans le nord-ouest de l'Algérie (région de Ténès).

La zone d'étude est choisie en raison de son importance dans le cadre de la stratégie nationale de lutte contre les risques naturels, notamment les inondations. De plus, un modèle CNN simple avec deux couches cachées a été construit pour résoudre la problématique évoquée, combiné avec une classification OBIA pour la classification de l'image Sentinel-2.

À l'échelle mondiale, il est devenu essentiel de modéliser, d'analyser et de surveiller l'occupation des sols. Les progrès considérables des applications de télédétection reposent sur la cartographie de l'occupation du sol, en se basant sur des méthodes de classification d'images. Dans cette optique, les tâches de cartographie de l'occupation du sol, en général, ont souvent été résolues en exploitant des approches traditionnelles telles que l'analyse basée sur les pixels et l'analyse basée sur les objets qui sont essentiellement fondées sur des algorithmes de Machine Learning (Khatami et al., 2016).

Malgré que l'application de l'approche de classification OBIA à la cartographie de l'occupation du sol a atteint un résultat satisfaisant démontré dans plusieurs études, par exemple, (Belgiu et Csillik, 2018 ; Georganos et al., 2018), le développement croissant très récemment de l'apprentissage profond, principalement les modèles CNN, est considéré comme un saut majeur dans le domaine de la télédétection appliquée sur différentes données satellitaires.

Le modèle CNN a démontré sa capacité à résoudre les problèmes de reconnaissance d'images, en particulier les tâches de l'occupation du sol. Plusieurs architectures basées sur des modèles CNN ont été développées pour répondre à cette question. (Pan et al., 2020) ont étudié la classification de l'occupation du sol à partir des données multispectrales LiDAR au moyen d'une architecture CNN profonde avec sept couches fonctionnelles fondamentales qui ont atteint de bons résultats d'OA avec une valeur de 96,9 %. De même, (Cao et al., 2019) ont évalué les performances des méthodes CNN pour la classification de l'occupation et l'utilisation des sols. Une base de données d'orthophotos a été fournie pour détecter les changements de l'occupation du sol dans la zone étudiée. Les résultats de l'étude indiquent la performance de l'architecture CNN proposée avec un OA plus de 90 %. De plus, (Liu et al., 2020) ont appliqué un modèle CNN avec une architecture particulière appelée *relation-Enhanced multiscale convolutional network*.

Le but était de classifier l'occupation du sol urbaine sur l'imagerie aérienne à haute résolution. Les résultats ont démontré que la méthode proposée peut détecter efficacement les catégories de l'occupation du sol urbaine et améliorer la précision de la classification produite avec un OA atteignant la valeur de 90,46 %.

En comparant les résultats de la méthode proposée dans cette thèse avec ceux d'autres recherches, l'approche combinant CNN et la classification OBIA a obtenu des résultats plus satisfaisants avec une valeur OA de 93,1 % et a montré son efficacité pour extraire les informations précises de l'occupation du sol.

Autrement dit, comme démontré dans la plupart des études listées ci-dessus, cette approche a surpassé les algorithmes de Machine Learning. Ainsi, dans ce travail, l'approche OBIA basée sur des algorithmes d'apprentissage automatique (RF et SVM), a obtenu une valeur OA de 92,2 % pour le classificateur RF et 79,6 % pour le classificateur SVM. La méthode CNN-OBIA a surpassé visiblement le classificateur RF (ordre à 0,9 % d'OA) (figure IV.31).

De plus, les résultats obtenus par cette méthode et les éléments d'occupation du sol extraits confirment les avantages de combiner les modèles d'apprentissage profond avec les méthodes traditionnelles de classification au niveau de l'image segmentée.

Les résultats obtenus dans cette étude ont été utilisés comme entité d'entrée dans la simulation du modèle hydraulique (cf. chapitre V).




Figure IV.31. Comparaison de la précision globale des résultats obtenus par les classificateurs RF, SVM et CNN.

IV.2.4. Évaluation des changements de l'occupation du sol dans le bassin versant de l'Oued Allala par l'utilisation de la méthode OBIA et les algorithmes de machine Learning à l'aide de l'imagerie satellitaire Landsat-5 TM et Sentinel-2

Le but de cette étude était de cartographier et de détecter les changements de l'occupation du sol sur 21 ans dans le bassin versant de l'Oued Allala. La méthode OBIA basée sur des classificateurs de Machine Learning et les applications SIG ont été implémentés pour l'analyse de deux images Landsat-5 TM et d'une image Sentinel-2. Ces images ont été acquises dans de

bonnes conditions de couverture nuageuse couvrant les années 1999, 2009 et 2020. Les classes d'occupation du sol en question définies sont principalement : constructions, forêt, sols nus, routes et terres agricoles. Deux algorithmes de Machine Learning, RF et SVM, ont été testés pour améliorer la précision de classification requise pour l'étape de détection des changements.

IV.2.4.1. Évaluation de la précision de la classification d'occupation du sol

Les résultats de l'évaluation de la précision des classifications indiquent des précisions globales (OA) élevées pour les images d'entrée Sentinel-2 et Landsat-5 TM. Le tableau IV.9 illustre les résultats des précisions globales (OA) et du coefficient de kappa des images classifiées pour les années 1999, 2009 et 2020. En comparant les algorithmes, le RF appliqué aux images Sentinel-2 (2020) a donné la plus grande précision avec une valeur 96,6 % de OA et 0,95 de kappa. La classification de l'occupation du sol à partir des images Landsat (1999) a également montré une grande précision avec un OA de 96,2 % et un coefficient kappa de 0,95. concernant l'algorithme SVM, les résultats OA et kappa étaient également relativement élevés, le meilleur résultat étant obtenu avec l'image Landsat 2009, avec un OA de 94,9 % et un kappa de 0,93.

Compte tenu de la classification Sentinel-2 (2020) obtenue par le classificateur RF, les précisions des classes obtenues en termes de PA et UA (tableau IV.9) ont été relativement élevées, notamment pour les classes; terres agricoles, routes et sols avec plus de 98 %. Cependant, les zones de constructions et les sols nus ont été relativement mal classées avec les valeurs 54.9 % et 54.8 % de UA. De même, pour la classification de l'occupation du sol Landsat-5 TM (2009), les constructions et la forêt ont été bien classés en termes de UA (97,8 % et 100 %). Les terres agricoles et les routes avaient des valeurs de UA de 94,6 % et 92,7 %. De même, pour la classification Landsat-5 TM de 1999, la forêt, les routes et les sols nus étaient bien détectées avec des précisions UA de 99,8 %, 99,8 % and 99.9 %.

Considérant les classifications par le classificateur SVM pour les trois années, les valeurs UA obtenues étaient nettement inférieures à celle obtenues par RF. En fait, pour la classification Sentinel-2 (2020), les terres agricoles et les routes ont été bien classées en termes de UA, avec des valeurs 90,7 % et 86,8 %, respectivement. Par contre, les zones bâties (constructions) et les sols nus étaient relativement mal classées ; le UA atteignant 54 % et 77 %, respectivement.

Pour l'année 1999, la classification obtenue par l'algorithme SVM, les forêts et les sols nus ont été bien classifiées, avec des valeurs de UA de 90 % et 85,6 %. Pour la classification 2009, les forêts et les terres agricoles ont été bien délimités par rapport aux autres classes, avec un UA

allant jusqu'à 99 % pour les deux classes. Pour cette année, les terres les routes sont mal classées, avec une faible valeur de UA (jusqu'à 66 %).

Dans l'ensemble, en comparant les deux types de données de télédétection utilisés pour produire des cartes établies basées sur des deux classificateurs, le RF a révélé plus de stabilité et a superposé SVM ; en particulier avec les données Sentinel-2, avec 0,4 % plus élevé que OA de la classification Landsat-5 TM (1999), et 1,7 % plus élevés que l'OA de la classification Landsat (2009).

En ce qui concerne le SVM, le meilleur résultat a été obtenu avec l'image Landsat de 2009, avec une différence significative de 18,3 % par rapport à celle de classification SVM 2020, et de 12,6 % par rapport aux résultats du SVM de 1999. Entre les deux algorithmes, quel que soit le type d'image d'entrée, la RF a surpassé le SVM de 20,4 % pour 2020, de 0,4 % pour 2009 et de 14,3 % pour 1999.

Tableau IV.9. Résultats d'évaluation de la précision de la classification

classe	Métriques (%)	1999		2009		2020	
		RF	SVM	RF	SVM	RF	SVM
Constructions	UA	98,1	80,9	97,8	91	97,7	54,9
	PA	99,9	92,7	93,8	98,9	100	96,6
Forêts	UA	99,8	90	100	99	97,71	81,7
	PA	92,6	86,7	92,2	99,9	100	86,8
Routes	UA	99,8	81,5	92,7	66,7	99,8	88
	PA	93,02	72,1	99,8	99,9	100	77,1
Terres agricoles	UA	88,2	71,3	94,6	95,3	98	82,9
	PA	98,9	84,6	94,6	87,2	90,9	90,7
Sols nus	UA	99,9	85,6	95,0	95,1	100	77,8
	PA	99,8	56,3	88,4	91	90	54,8
OA (%)		96,2	81,9	94,9	94,5	96,6	76,2
Kappa		0,95	0,7	0,93	0,93	0,96	0,7

IV.2.4.2. Analyse des changements de l'occupation du sol

Les cartes issues de la classification de l'occupation du sol implémentées par les deux modèles (RF et SVM) pour les années 1999, 2009 et 2020 sont illustrées dans les figures IV.32- IV.37.

D'après une analyse visuelle on peut constater que l'occupation du sol a subi des changements considérables entre 1999 et 2020.

De plus, selon les résultats des calculs de superficies pour chaque classe représentée dans le tableau IV.10, des changements dans les tendances ont été observés pour tous les catégories de l'occupation du sol ;

Tableau IV. 10. Superficies des classes d'occupation du sol

	1999		2009		2020	
	Superficie (ha)	% de la superficie totale	Superficie (ha)	% de la superficie totale	Superficie (ha)	% de la superficie totale
Constructions	537,2	1,7	2339,3	7,6	3720,1	12,1
Forêts	4957,4	16,1	5652,2	18,4	4300,1	14
Routes	96,7	0,3	3736	12,2	4714,1	15,4
Terres agricoles	16 387,8	53,4	15 001	48,8	15 307,5	49,9
Sols nus	8726,6	28,4	3979	13	2664	8,7

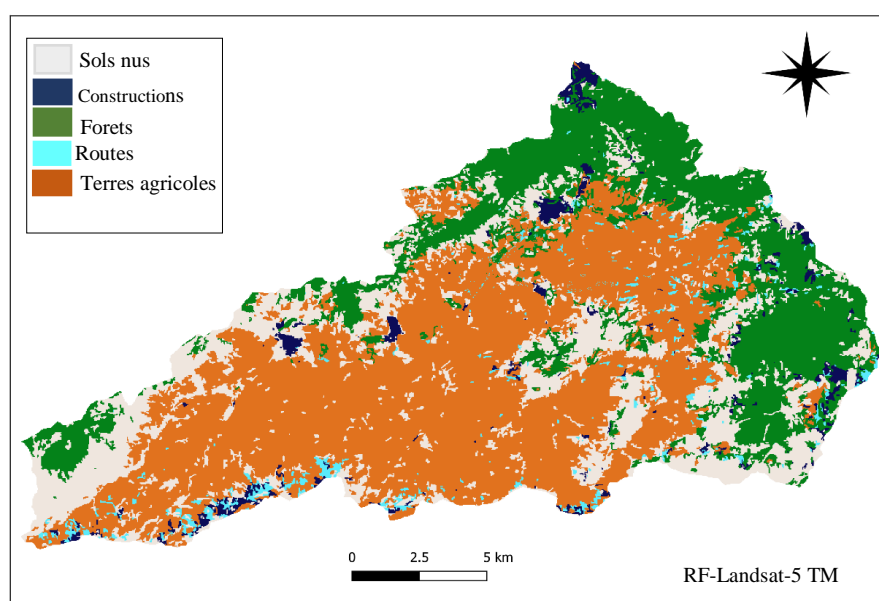


Figure IV. 32. Classification d'occupation par RF (image Landsat-5 TM, année 1999).




Figure IV.33. Classification d'occupation par SVM (Landsat-5 TM, année 1999).




Figure IV.34. Classification d'occupation par RF (Landsat-5 TM, année 2009).

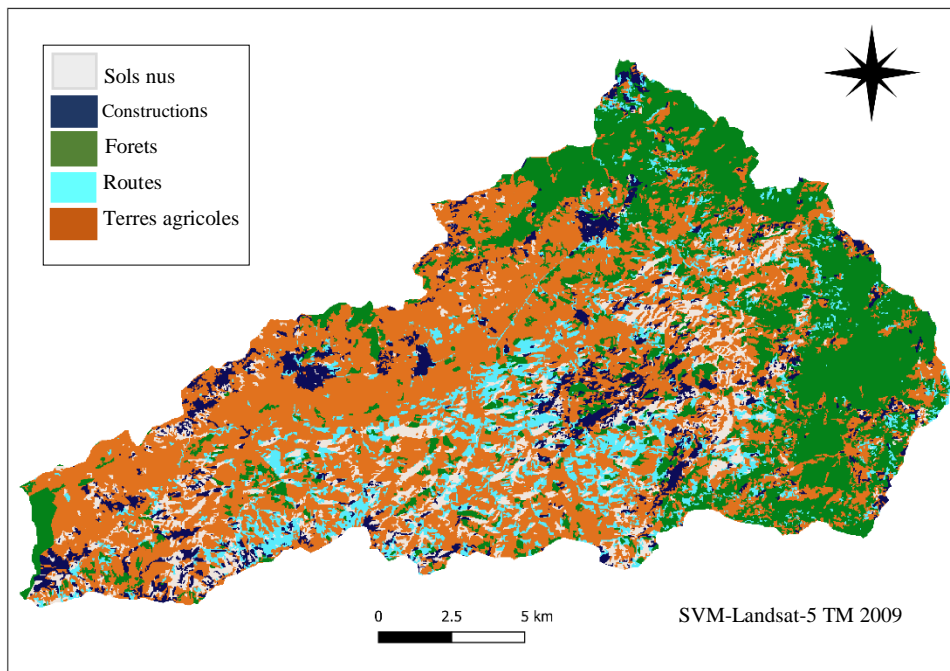


Figure IV.35. Classification d'occupation par SVM (Landsat-5 TM, année 2009).




Figure IV.36. Classification d'occupation par RF (image Sentinel-2, année 2020)

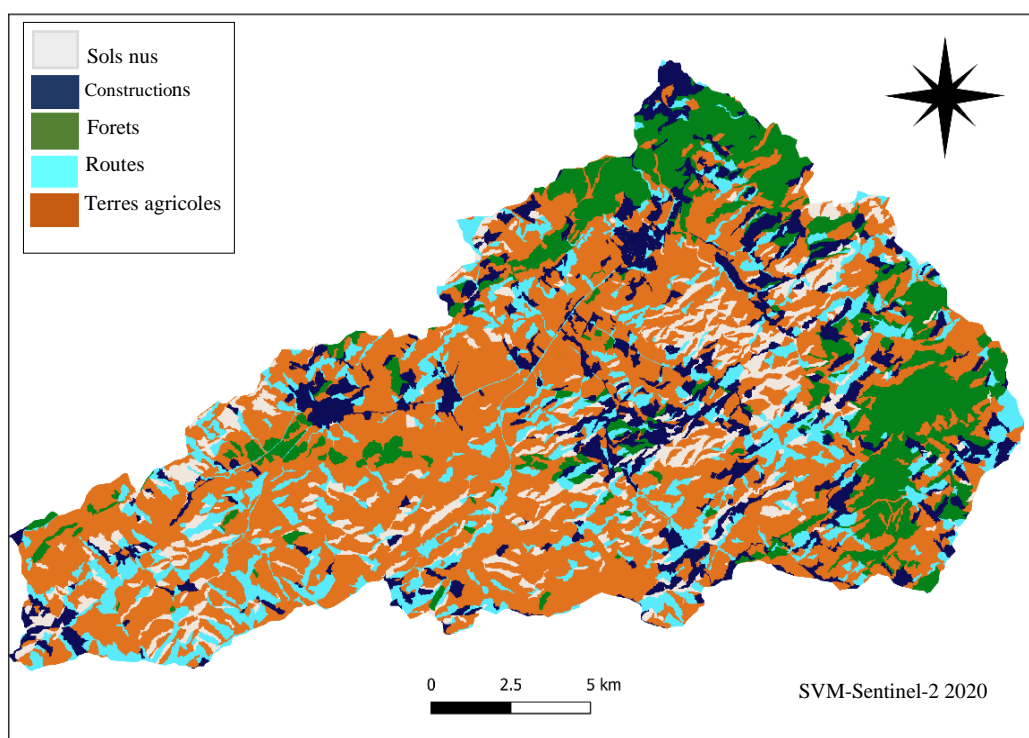


Figure IV.37. Classification d'occupation par SVM (image Sentinel-2, année 2020).

En effet, en 1999, le bassin versant d'Oued Allala était dominé par les terres agricoles, avec un pourcentage de 53 % de la superficie totale de bassin versant, suivies par les sols nus (28 %), les forêts (16,1 %), les constructions (1,7 %), et enfin les routes (0,3%).

En 2009, des changements considérables ont également été observés dans les tendances de l'occupation du sol. Autrement dit, la superficie des routes ait augmenté de manière significative (de 0,2 % à 12,2 %) par rapport à la superficie totale. De même, la classe constructions a étendu de façon remarquable (figure IV.34 et tableau IV.10).

En revanche, la classe sol nus a subi une diminution significative (de 28,4 % à 13 %) de la superficie totale.

En 2020, on constate une diminution similaire pour la classe des sols nus, qui passe à 8,7 % de la superficie totale. Parallèlement, les routes et les constructions ont continué à augmenter, et on a constaté une légère augmentation de la superficie des terres agricoles (de 48,8 % à 49,9 %). Une légère diminution a également été observée dans les forêts (de 18,4 % à 14 %) de la superficie totale de l'occupation du sol.

De manière générale, au cours des trois années, les terres agricoles de démarquent la classe la plus dominante en termes de superficie par rapport aux autres classes.

Il est à souligner qu'au cours de la période étudiée (1999-2020), le bassin versant de l'Allala a connu des changements considérables dans les catégories de l'occupation du sol, où une diminution dans certaines classes correspondait à une augmentation dans d'autres. Ces changements peuvent être mieux expliqués en analysant la matrice des transitions de ces catégories.

IV.2.4.3. Analyse de matrices de transition

Les résultats détaillés des matrices de transition pour les périodes 1999-2009 et 2009-2020 sont présentés dans les tableaux IV.11 et IV.12. L'analyse des matrices de transitions indique des tendances significatives dans les transitions de l'occupation du sol d'une catégorie à une autre. Conformément au tableau IV.11 (1999-2009), un taux de transition élevé a été observé dans la classe forêts, qui s'est convertie en terres cultivables avec 773,4 ha, en sols nus avec 5989,5 ha, en sols nus avec 1185,5 ha, 1577,3 ha et 3180,7 ha respectivement.

Tableau IV.11. Matrice de transition pour la période 1999-2009.

Classes (1999) (ha)	Classes (2009) (ha)					
	Constructions	Forêts	Routes	Terres agricoles	Sols nus	Total
Constructions	359,7	15,8	30,5	34,9	92,6	533,4
Forêts	14	3659	131,1	773,4	368,5	4946
Routes	7,7	7,1	10,7	27,1	43,9	96,5
Terres agricoles	373,7	1344,1	2373,7	6294,7	5989,5	16375,7
Sols nus	1577,3	611,9	1185,5	3180,7	2152,8	8708,2
Total	2332,3	5637,9	3731,6	10310,7	8647,3	30659,8

En ce qui concerne les transitions entre 2009 et 2020 (tableau IV.11), les transitions les plus significatives ont été signalées pour la forêt en terres cultivables avec 1436,8 ha pour la zone forestière totale, les terres stériles en terres cultivables, avec 1896,6 ha, et les routes avec 1544,1 ha, et les terres cultivables en sols nus, routes et constructions, avec 2153,8 ha, 1664,9 ha, et 1173,6 ha, respectivement.

Tableau IV.12. Matrice de transition pour la période 2009-2020

Classes 2009 (ha)	Classes 2020 (ha)					
	Constructions	Forêts	Routes	Terres agricoles	Sols nus	Total
Constructions	977,5	20,3	486,7	119,0	729,8	2333,4
Forêts	338,0	3186,8	176,3	1436,8	502,9	5640,8
Routes	570,9	122,6	833,3	898,0	1307,5	3732,3
Terres agricoles	1173,6	624,3	1664,9	4698,2	2153,8	10314,9
Sols nus	652,9	341,7	1544,1	1896,6	4214,0	8649,3
Total	3713,0	4295,8	4705,3	9048,6	8908,0	30670,8

L'étude a permis de cartographier et d'évaluer les changements d'occupation des sols dans le bassin versant Oued Allala sur 21 ans. La méthode OBIA appliquée à deux images Landsat-5 TM prises en 1999 et 2009 et une image Sentinel-2 prise en 2020 a permis d'identifier les changements d'occupation du sol et la répartition des superficies des classes par rapport à la superficie totale de bassin versant sur les trois années étudiées (1999, 2009 et 2020).

Les algorithmes d'apprentissage automatique RF et SVM ont tous deux obtenu de bons résultats, avec une précision globale comprise entre 76 % et 96 %. En outre, l'algorithme RF a surpassé le SVM dans toutes les classifications, indépendamment des types d'images satellitaires utilisés dans le processus de classification. Ceci est mentionné certaines études, par exemple, (Adugna et al., 2022; Ghosh and Joshi, 2014; Htitiou et al., 2019; Niculescu et al., 2020; Zaabar et al., 2021). En parallèle, l'optimisation des paramètres des classificateurs utilisés nous a permis d'obtenir de meilleurs résultats avec des valeurs élevées de la précision globale.

De plus, nos expériences ont montré que la RF a été mieux exécuté avec l'image Sentinel-2 qu'avec les images Landsat-5 TM et il a apporté les valeurs les plus élevées de la précision globale (jusqu'à 96%). Ces résultats confirment l'efficacité et la robustesse de cet algorithme lorsqu'il est appliqué à ce type de données, notamment pour la cartographie de l'occupation du sol ; Cela s'explique fortement par l'effet de la résolution spatiale.

Par ailleurs, les précisions par classes ont également été évaluées par les deux classificateurs pour les trois années (Tableau IV.9). Ainsi, pour 1999 et 2020, les zones de constructions et les sols nus ont été bien détectés par le classificateur RF, avec des valeurs de UA et de PA supérieures à 96 %. Pour 2009, la forêt a été bien classée avec un UA et un PA de plus de 92 %. Cependant, la classe la plus mauvaise en termes de UA et de PA était les sols nus avec des

valeurs proches de 54%. Cependant, nous pouvons constater visiblement une limitation de la classification OBIA ; malgré les valeurs grandes de la précision globale et les précisions par classes notamment pour la classe routes, cette classe n'a pas été bien délimitée et elle a pris une superficie grande par rapport aux autres classes. Cela est dû à l'effet de la segmentation de l'image satellitaire et en particulier au paramètre « échelle » qui a généré des grands segments affectant ensuite la classification finale.

En tenant compte l'évaluation des changements de l'occupation du sol sur les deux périodes : 1999-2009 et 2009-2020, tels qu'observés sur les classifications finales, en plus des résultats présentés dans le tableau IV.10, le bassin versant de l'Allala a subi différentes tendances de changements au cours des années étudiées. Au même temps, selon les résultats de calcul de la matrice de transition sur 1999-2009 et 2009-2020 (Tableaux IV.11 et IV.12), ils y avaient des transitions considérables d'une classe à une autre.

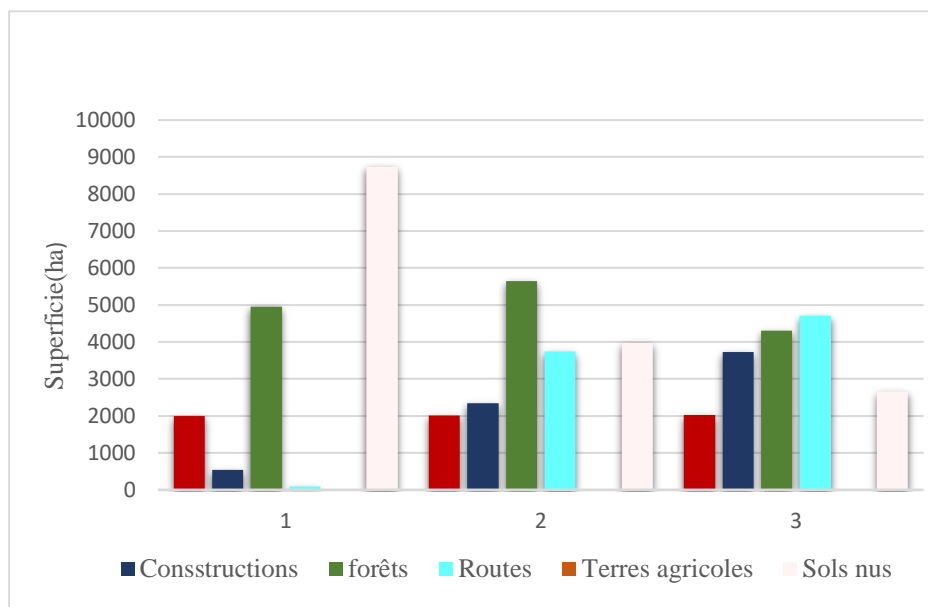


Figure IV.38. Superficie des classes d'occupation du sol par rapport à la superficie totale en (ha) en 1999, 2009 et 2020.

De toute évidence, on observe une forte augmentation de la superficie des zones de constructions et des routes, ce qui s'est expliqué par la croissance démographique et l'urbanisation qui en découle. Cela a également impliqué la transition de certaines classes vers les zones de constructions et les routes. Cette augmentation significative a été compensée par une forte diminution de la classe des sols nus, de 15,4 % entre 1999 et 2009, et de 4,3 % entre 2009 et 2020. Plus précisément, le taux de changement est plus important au cours de la période

1999-2009. Ces résultats sont logiques, car la ville de Ténès a connu une construction urbaine constante au cours des dernières décennies.

De même, la classe forestière a diminué de 2,1% entre 1999 et 2020. Ceci s'explique par la dégradation des écosystèmes des bassins versants et les nombreux incendies de forêt qu'a connus cette région. Par ailleurs, la classe des terres cultivables, qui occupe la plus grande proportion de la superficie totale du bassin versant (53,4 % en 1999), a diminué de 4,6 % de 1999 à 2009, puis augmenté de 1,1 % de 2009 à 2020. Cette transition est généralement liée à la saison de récolte au moment où les images satellites ont été acquises.

La classe forêts a été convertie en sols nus (7,7 %) et en terres agricoles (15,6 %). En ce qui concerne les transitions entre 2009 et 2020, les transitions les plus importantes ont été signalées pour les forêts en terres agricoles (16 %), et les sols nus en zones constructions (18 %), routes (14 %) et terres agricoles (37 %). Ceci s'explique par la dégradation, les feux de forêts dans le bassin versant de l'Allala et aussi au déboisement illégal dans la région.

Discussion générale et conclusion

Ce chapitre s'est principalement focalisé sur l'exposition des méthodologies mises en œuvre dans cette thèse pour la classification de l'occupation du sol dans le contexte de l'étude des zones inondables. Dans cette optique, trois principales analyses de l'occupation du sol ont été explorés :

- (1) Synergie des données optiques et radar pour la cartographie de l'occupation du sol de la ville côtière Ain Témouchent par méthodes de Machine Learning.
- (2) Application des réseaux de neurones convolutifs (CNN) combinés avec la méthode OBIA (Object Based Image Analysis) pour la cartographie de l'occupation et de l'utilisation du sol dans la zone côtière Ain Témouchent, Algérie.
- (3) Évaluation de la combinaison des réseaux neuronaux convolutifs (CNN) et la méthode OBIA (Object Based Image Analysis) pour la classification de l'occupation du sol à l'aide de l'imagerie satellitaire Sentinel-2 dans la région de Ténès.
- (4) Détection des changements de l'occupation du sol dans de bassin versant de l'Oued Allala.

A la lumière de l'application de ces différentes analyses, plusieurs conclusions peuvent être déduites:

- Les analyses effectuées dans ce chapitre ont permis de modéliser l'occupation du sol de deux zones d'étude, à l'ouest algérien, exposées au risque d'inondation. Différentes approches de classification supervisée ont été testées pour extraire précisément les éléments de l'occupation du sol, à savoir les méthodes basées sur les classificateurs de Machine Learning et autres basées sur les modèles profonds. De même, différentes sources de données satellitaires ont été exploitées afin d'évaluer l'apport de l'imagerie satellitaire pour la cartographie de l'occupation du sol dans le contexte de l'étude des inondations.
- La classification de l'image satellitaire issue d'une approche synergique des données satellitaires optique-radar de Sentinel-1 et Sentinel-2 a permis de combiner les informations nécessaires pour la reconnaissance des types de l'occupation du sol de la ville côtière Ain Témouchent. Les approches de classification ont été entreprises par les deux algorithmes de *Machine Learning Random Forest (RF)* et *support Vector machine (SVM)*. Après un processus d'optimisation, les résultats satisfaisants obtenus ont confirmé la robustesse et la performance de l'algorithme RF. Il est noté que l'approche orientée objet a eu plus de pertinence, avec un indice de précision globale de l'ordre de 96%, par rapport à celle pixel par pixel (92 %).
- Dans le cas de l'analyse l'occupation du sol dans la zone côtière d'Ain Témouchent par la combinaison des réseaux de neurones convolutifs (CNN) et la méthode OBIA (Object Based Image Analysis), un modèle d'apprentissage profond CNN développé en combinaison avec OBIA a été appliqué, et des méthodes d'apprentissage automatique basées sur des classificateurs RF et SVM ont été testées pour la comparaison. Les méthodes proposées ont été menées sur deux types de données de télédétection différents, les données Pléiades THRS et Sentinel-2 à haute résolution spatiale, dans le but de tester la contribution et le potentiel de chaque jeu de données dans l'extraction des caractéristiques de l'occupation du sol. Les paramètres de l'architecture CNN, en particulier la taille des échantillons de patches et des couches CNN (y compris les couches cachées, de convolution et de mise en commun maximale) ont été optimisées pour produire une architecture de modèle optimale et améliorer la précision de la classification. Le modèle CNN proposé, intégré à OBIA, a montré des précisions significatives dans la cartographie l'occupation du sol par rapport à d'autres classificateurs de Machine Learning, atteignant un OA et un kappa de 93,5 % et 0,91 pour les données Pléiades, respectivement, et 83,4 % et 0,80 pour les données Sentinel-2. En outre, malgré la capacité des modèles CNN à extraire les caractéristiques de

l'occupation du sol à haut niveau, la méthode OBIA a son impact notable sur la précision de classification, en particulier l'optimisation des paramètres de segmentation. Dans le même sens, le paramètre d'échelle dans la segmentation multirésolution est essentiel pour contrôler la taille des objets segmentés, et devrait être optimisé pour améliorer la classification OBIA.

- Les résultats obtenus dans cette analyse ont révélé qu'il est possible de cartographier l'occupation du sol dans les zones côtières en utilisant des algorithmes de Machine Learning appliqués à des données ayant des résolutions spatiales différentes. En conséquence, les cartes finales ont des précisions différentes, et le niveau des classes de l'occupation du sol détectées dépend de la résolution choisie. Malgré la résolution inférieure des données Sentinel-2, des cartes visiblement utilisables ont été produites. Par conséquent, pour des analyses plus détaillées qui nécessitent des détails à une échelle fine, l'utilisation de produits VHSR est recommandée, notamment dans les zones côtières hétérogènes. Les cartes finales produites ici peuvent servir de base de données pour l'évaluation de la vulnérabilité aux inondations, qui nécessitent des informations détaillées sur l'occupation du sol pour l'étape de la simulation hydraulique. Les cartes produites peuvent également être considérées comme un outil utile pour soutenir la prise de décision au niveau régional et national concernant l'occupation du sol dans les zones à risque d'inondation dans la région côtière d'Ain Témouchent.
- Dans le cas de l'analyse de l'occupation du sol de la ville côtière de Ténès avec la même méthode basée sur les réseaux neuronaux convolutifs (CNN) combinée avec OBIA. La méthode proposée a été expérimentée sur un ensemble des combinaisons spectrales de Sentinel-2. L'objectif est d'analyser et d'évaluer l'occupation du sol et discriminer les classes d'occupation du sol. Les expériences ont été menées sur une ville côtière située dans le nord-ouest de l'Algérie (région de Ténès). Les résultats de l'évaluation de la précision montrent les meilleures valeurs de la précision globale (93 %). En outre, la comparaison de l'approche CNN-OBIA avec l'approche OBIA basée sur des algorithmes de Machine Learning (RF et SVM). (RF et SVM) indique que l'approche que nous avons proposée a surpassé et a mieux fonctionné que l'approche OBIA basée sur ces classificateurs.
- En outre, la comparaison des résultats de la classification l'occupation du sol appliquée à différentes combinaisons d'indices et bandes spectrales de Sentinel-2 avec celle d'une image Sentinel-2 contenant que ses bandes spectrales a montré une amélioration significative des résultats de classification menée en tirant profit des informations

spectrales. Le OA obtenu par cette combinaison a atteint 93 % et a surpassé la classification Sentinel-2 (OA= 83,4 %) par environ 10%. Par conséquent, les fonctionnalités spectrales Sentinel-2 riches en informations présentent un grand potentiel qui peut être conçue pour l'analyse l'occupation du sol avec une grande précision.

- L'approche expérimentée pour la cartographie et l'évaluation des changements d'occupation du sol a été appliquée avec la classification OBIA en exploitant deux images Landsat-5 TM, prises en 1999 et 2009, et une image Sentinel-2 de 2020. Cette approche a permis d'identifier les changements d'occupation du sol et la distribution des classes par rapport à la superficie totale de bassin versant sur 21 ans. Les classificateurs de Machine Learning appliqués selon l'approche OBIA ont obtenu des précisions élevées de la classification (> 90% de précision globale). Plus précisément, le classificateur RF a surpassé le SVM avec l'ensemble des données satellitaires exploité sur les 3 années (> 96%). En outre, la méthodologie proposée a combiné les résultats de la télédétection avec les outils du système d'information géographique (SIG) afin d'évaluer efficacement les changements de l'occupation du sol.
- Selon les résultats de la détection des changements de l'occupation du sol, Oued Allala a subi de nombreux changements au fil du temps. Ces résultats confirment que la région a subi de nombreux changements environnementaux au cours des dernières décennies en raison de la croissance de la population, de l'urbanisation et de l'évolution des zones agricoles. Les changements notables comprennent une augmentation des classes de constructions (15,4 %), de terres agricoles (1,1 %) et de routes (10,9 %), et une diminution des superficies des forêts (4,4 %) et des sols nus (4,3 %). Le taux de changement est donc plus important dans la période 1999-2009. Ces statistiques sont raisonnables, car la ville de Ténès était encore en construction urbaine durant cette période. Cependant, l'analyse des résultats de la matrice des transitions a montré que les transitions les plus significatives ont été rapportées pour les forêts en terres agricoles (16%), ce qui est confirmé par la déforestation, les feux et la dégradation des forêts dans cette région. Les terres stériles ont également transité en terres bâties (18 %), en routes (14 %) et en terres cultivables (37 %).
- L'analyse et la cartographie des tendances des changements de l'occupation du sol dans le bassin versant Oued Allala fournissent une base pour l'étude de risque d'inondation selon une approche multicritère, pour la planification stratégique et outil d'aide à la décision et contribuer à la gestion régionale et nationale des terres.

- Dans le cadre du suivi de la vulnérabilité aux risques d'inondations fluviales, les produits de haute résolution spatiale Landsat-5 TM, Sentinel-1 et Sentinel-2 avec leur avantage de libre droit, offrent la possibilité d'analyser des enjeux susceptibles d'être menacés. Cependant, les approches développées avec ces données ainsi que la fusion des deux capteurs des produits Sentinel et compte tenant l'effet de la résolution spatiale ont mis en valeurs des classes appartenant au niveau 2, dans un barème de 3 niveaux, d'une nomenclature adaptée au risque d'inondation. Les cartes finales ainsi que l'analyse du cas d'étude sont considérées comme des outils d'aide à la prise de décision et à la planification spatiale au niveau régionale. Par conséquent, l'exploitation des données THRS Pléiades a permis de tester les méthodes de classification pour détecter les classes du niveau supérieur (détaillé), ce qui est requis pour la détermination détaillée de la vulnérabilité du risque, mener à une grande précision lors de la modélisation des scénarios de risque et à l'élaboration des Plans de Prévention des Risques d'Inondation.

Au vu de ses résultats, et tenant compte les résultats tirés, le chapitre suivant s'intéresse à l'application des résultats de cartographie de l'occupation du sol dans une approche de modélisation des scénarios d'inondation. Pour la modélisation d'inondation, les résultats de cartographie de l'occupation du sol obtenus par les Sentinel-2 (à travers la région Ténès) et ceux obtenus par l'image Pléiades ont été exploitées à l'amont du modèle et au post traitement hydraulique. Le bassin versant choisi pour effectuer la démarche envisagée et celui de l'Oued Allala.

PARTIE III :
APPROCHES
METHODOLOGIQUES

CHAPITRE V

ÉVALUATION DU RISQUE D'INONDATION
EN MILIEU URBAIN A PARTIR DES
DONNEES SATELLITAIRES ET LA
MODELISATION HYDRAULIQUE

CHAPITRE V : ÉVALUATION DU RISQUE D'INONDATION EN MILIEU URBAIN A PARTIR DES DONNEES SATELLITAIRES ET LA MODELISATION HYDRAULIQUE

Introduction

La modélisation hydraulique des événements extrêmes a été introduite depuis plusieurs décennies. Elle vise à simuler la propagation de l'onde de crue dans un canal d'écoulement et déterminer l'étendue des inondations dans une plaine inondable.

Plusieurs modèles performants ont été développés pour les analyses hydrauliques et la simulation des crues fluviales. Parmi ceux-ci, il y a le modèle fréquent HEC-RAS (*Hydrologic Engineering Center's River Analysis System*). Ce modèle propose des analyses unidimensionnelles (1D), bidimensionnelles (2D) et combinées (1D/2D) des rivières et des canaux naturels.

Par ailleurs, les méthodes et les approches ainsi développées récemment ont permis d'intégrer des outils performants aux analyses hydrauliques tel que la télédétection. Ces outils fournissent des informations précieuses sur l'occupation du sol et la topographie de la rivière et la plaine inondable et peuvent faciliter la modélisation hydraulique.

L'occupation du sol joue un rôle important dans l'évaluation du risque d'inondation à partir des caractéristiques hydrodynamiques d'écoulement des étendues affectées par les ruissellements ou l'onde de crue.

En outre, la topographie demeure un facteur clé dans l'évaluation du risque à partir de la précision globale de la cartographie des inondations. Ces données de terrain offrent aux modèles numériques des enseignements intéressants dans la création d'un modèle hydrodynamique caractérisant la cartographie de l'étendue de l'inondation.

Les modèles numériques d'élévation (MNT) ou de la surface (MNS) à haute résolution permettent d'extraire les détails de la topographie, d'acquérir les élévations de la surface de l'eau et de simuler l'inondation et sa profondeur avec une grande précision (Sarhadi et al., 2012).

Dans ce chapitre, nous proposons une approche méthodologique de la modélisation et de la cartographie des zones inondables de notre zone d'étude située à proximité de la région côtière. L'approche intègre les résultats issus précédemment de la classification de l'occupation du sol à partir des images satellitaires Pléiades et Sentinel-2, des modèles numériques d'élévation qui

ont été également générées à partir des capteurs satellitaires ALOS et Pléiades tri-stéréo à très haute résolution spatiale et les résultats d'analyses hydrologiques et hydrauliques.

V.1. Analyse fréquentielle des crues et détermination des débits extrêmes

L'analyse de la fréquence des inondations extrêmes est une étape indispensable pour évaluer les risques d'inondation et, éventuellement, pour atténuer leurs conséquences catastrophiques. C'est l'une des études importantes de l'hydrologie fluviale visant à déterminer la probabilité d'occurrence future d'un événement en s'appuyant sur l'analyse statistiques des données hydrologique historiques.

Par conséquent, l'analyse de la fréquence des crues dans cette étude a été effectuée à partir de données hydrométriques disponibles au niveau de la station Sidi Akkacha, contrôlant le bassin versant de l'Oued Allala. Cette analyse comprend essentiellement la vérification de l'homogénéité, l'indépendance et la stationnarité de la série hydrométrique exploitée, l'ajustement de la série hydrométrique aux lois probabilistes et la sélection de la meilleure distribution pour le calcul des quantiles pour différentes périodes de retour.

V.1.1 Tests d'homogénéité des séries

Les tests d'homogénéité sont destinés à la vérification de l'indépendance et de la distribution identique des observations chroniques. Dans ce sens, des tests d'homogénéité de Wilcoxon (Kosiorowski et al., 2019), d'indépendance (Wald et Wolfowitz, 1943) et de stationnarité ont été appliqués sur la série étudiée des débits:

V.1.1.1. Test d'homogénéité

Le test de Wilcoxon est l'un des tests les plus couramment utilisés pour évaluer l'homogénéité d'une série de données hydrologiques. Il permet de comparer deux sous-échantillons et vérifier que leurs moyennes sont significativement différentes. La statistique de ce test V est asymptotiquement distribuée selon une distribution normale centrale réduite, exprimée comme suit :

$$V = \frac{0.5m(n+1) + 0.5}{\sqrt{\text{Var}(W)}} \quad (\text{V.1})$$

Où :

$$W = \sum_{i=1}^m R_i S(R_i) \quad (\text{V.2})$$

Où

R_i : est le rang du classement des variables aléatoires des deux sous séries combinées et triées en ordre croissant.

$s(R_i)$: est le facteur multiplicateur égal à 0 si la donnée est effectuée après le changement.

$Var(W)$: est la variance de la statistique et s'écrit par la formule suivante :

$$Var(W) = \frac{n(m-n)(m+1)}{12} - \frac{n(m-n) \sum_{i=1}^k (d_k^3 - d_k) x^2}{12(m-1)} \quad (V.3)$$

Où

K : est le nombre de séries distinctes contenant des observations égales.

d_k : est le nombre d'observations égales dans chacune des séries.

V.1.1.2. Test d'indépendance

Lorsqu'il n'y a pas d'autocorrélation entre les événements, les échantillons sont dits indépendants. L'indépendance des événements continus retenus lors de l'échantillonnage peut être vérifiée à l'aide du test de Wald-Wolfowitz, qui se calcule comme suit :

$$W = \sum_{i=1}^{n-1} (X_i X_{x+1}) + (X_i X_n) \quad (V.4)$$

V.1.1.3. Test de stationnarité

Une série est considérée stationnaire si ses caractéristiques statistiques (par exemple : moyenne, variance) ne varient pas en fonction du temps. L'un des tests statistiques les plus largement utilisé pour tester l'hypothèse de stationnarité est le test de Mann-Kendall. Ce test compare les hypothèses suivantes

- H_0 : les caractéristiques statistiques des variables aléatoires sont constantes dans le temps.
- H_1 : les caractéristiques statistiques des variables aléatoires ne sont pas constantes dans le temps.

La statistique S de ce test est exprimée par la formule suivante:

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{signe}(X_j - X_i) \quad (V.5)$$

Plus la statistique du test S tend vers la valeur 0, plus les observations seront considérées comme stationnaires.

V.1.2. Modèles d'ajustement et détermination des débits extrêmes

Conformément au type de crues qui caractérise le nord Algérien et notamment la région étudiée, de multiples lois d'ajustement ont été testées sur la série de débits instantanés maxima, à savoir : Gumbel, Log Normale deux et à trois paramètres, Pearson type III (Gamma). La loi de distribution de probabilité Gumbel est appliquée fréquemment dans les études hydrologiques et météorologiques pour la prédiction des pics de crues et des précipitations maximales. En outre, la distribution log-normale se trace comme une ligne droite sur un papier de probabilité logarithmique et la variante est d'abord transformée en forme logarithmique (base 10) et les données transformées sont ensuite analysées. En ce qui concerne la loi de distribution Log Pearson Type III, le fonctionnement est pratiquement similaire à celui Log Normale sauf que le coefficient d'asymétrie est différent de zéro. Les fonctions de densité de probabilité des modèles utilisés pour l'ajustement sont rapportées dans le Tableau V.1.

Tableau V.1. Fonctions de distribution de probabilité utilisées.

Modèle	Fonction de distribution	Paramètres
Gumbel	$f(x) = e^{-e^{-\frac{x-\beta}{\alpha}}}$	La caractéristique de la dispersion α Le mode (la valeur la plus probable) β
Log normal à deux paramètres	$f(x) = \frac{1}{\sigma x \sqrt{2\pi}} e^{-\frac{(\ln(x)-\mu)^2}{2\sigma^2}}$	
Log normal à trois paramètres	$f(x) = \frac{1}{\sigma(x-m)\sqrt{2\pi}} e^{-\frac{(\ln(x-m)-\mu)^2}{2\sigma^2}}$	L'écart-type σ L'espérance μ
Log Pearson type III	$f(x) = \frac{\alpha^\lambda}{x\Gamma(\lambda)} \ln(x-m)^{\lambda-1} e^{-\alpha(\ln(x-m))}$	L'espérance α L'écart-type λ La fonction gamma $\Gamma(\lambda)$

V.1.3. Choix de la loi d'ajustement

La loi d'ajustement choisie pour déterminer les quantiles correspondants aux périodes de retour est celle qui convient le mieux à la série de données hydrologiques. Pour cela, en plus des graphiques d'ajustement, des critères de sélection basés sur la fonction de vraisemblance ont été appliqués, à savoir le critère informatif AIC (information criterion Akaike) (Akaike, 1974)

et le critère Bayésien BIC (Bayesian information criterion). (Schwartz, 1978). Leurs fonctions sont données par les formules suivantes :

$$AIC = -2 \log(L) + 2k \quad (V.6)$$

$$BIC = -2 \log(L) + 2k \log(N) \quad (V.7)$$

Où

L : est la fonction de vraisemblance.

K: le nombre de paramètres.

N : la taille de l'échantillon.

Ces critères emploient le nombre de paramètres k, et le choix du meilleur ajustement est liée aux valeurs les plus petites de fonctions BIC et AIC (Rao et Hamed, 2001; Trambly et al., 2008).

V.1.3. Construction de l'hydrogramme des crues

La méthode de construction de l'hydrogramme des crues consiste à tracer des courbes à partir de deux équations paraboliques, une pour la montée de la crue l'autre pour la décrue. Les équations de la montée et la décrue sont exprimées comme suit:

- Equation de montée : $Q(t) = Q_{\max} \left(\frac{t}{t_c}\right)^n \quad (V.8)$

- Equation de la décrue : $Q(t) = Q_{\max} \left(\frac{T_b - t}{T_b}\right)^n \quad (V.9)$

- $T_b = T_d + T_m \quad (V.10)$

Où :

Q(t) : Débit instantané au moment (t) (m³/s) ;

Q_{max} : Débit maximum de fréquence donnée (m³/s) ;

T_m, T_d : Temps de montée et de décrue (h) ;

T_b : Temps de base de la crue (h).

m, n: Puissance des paraboles pour les bassins de petits gabarits (m=3, n=2).

T_c : temps de concentration du bassin versant (h).

Dans cette étude, six périodes de retours ont été prises en compte pour le calcul de l'hydrogramme des crues pour la modélisation hydraulique, principalement : 2, 5, 10, 20,50 et 100 ans.

V.1.3.1. Calcul du temps de concentration

Le temps de concentration est défini comme le temps nécessaire à une goutte d'eau de pluie pour parcourir la distance depuis le point le plus éloigné de l'exutoire d'un bassin jusqu'à celui-ci. Le temps de concentration est fonction de nombreux paramètres tels que la topographie, la géologie, l'utilisation des terres dans le bassin versant, l'imperméabilité des sols, etc. Le temps de concentration est utilisé pour les calculs de prédiction des débits de l'hydrogramme de crues résultant d'événements pluvieux basés sur des statistiques dérivées des périodes de retour. Pour le calcul du temps de concentration, la formule de Giandotti (1934) adaptée au nord algérien a été utilisée. Cette formule a été exprimée comme suit :

$$T_c = \frac{4\sqrt{S} + 1.5L_{cp}}{0.8\sqrt{H_{moy} - H_{min}}} \quad (V.11)$$

Où;

- T_c : Temps de concentration (h) ;
- L_{cp} : Longueur du cours d'eau principal (Km) ;
- S : Surface du bassin versant (Km²) ;
- H_{moy} : Altitude moyenne du bassin versant (m) ;
- H_{min} : Altitude minimale du bassin versant (m).

V.2. Modélisation hydraulique

Les simulations hydrauliques sont conçues pour représenter l'extension des ondes de crue dans les rivières, délimiter les plaines inondables et simuler les niveaux d'eau. Les modèles numériques constitués de modèles de surface d'eau unidimensionnels ou bidimensionnels utilisent des modèles numériques pour la simulation. Dans notre cas, l'analyse du modèle hydraulique a été réalisée sous HEC-RAS à partir des résultats de l'analyse hydrologique et la détermination de l'hydrogramme des crues, des cartes de l'occupation du sol et les données topographiques représentées par le MNT de 12 m et le MNS généré à partir de l'image Pléiades tri-stéréo. Le tronçon aval du bassin versant de l'Oued Allala situé à proximité de la cote a été choisi pour effectuer la simulation hydraulique. Il s'agit de la ville de Ténès où il y a de cadre

bâti et quelques surfaces agricoles susceptibles d'être touchés en cas d'inondation. La méthodologie employée est représentée dans la Figure V.1.

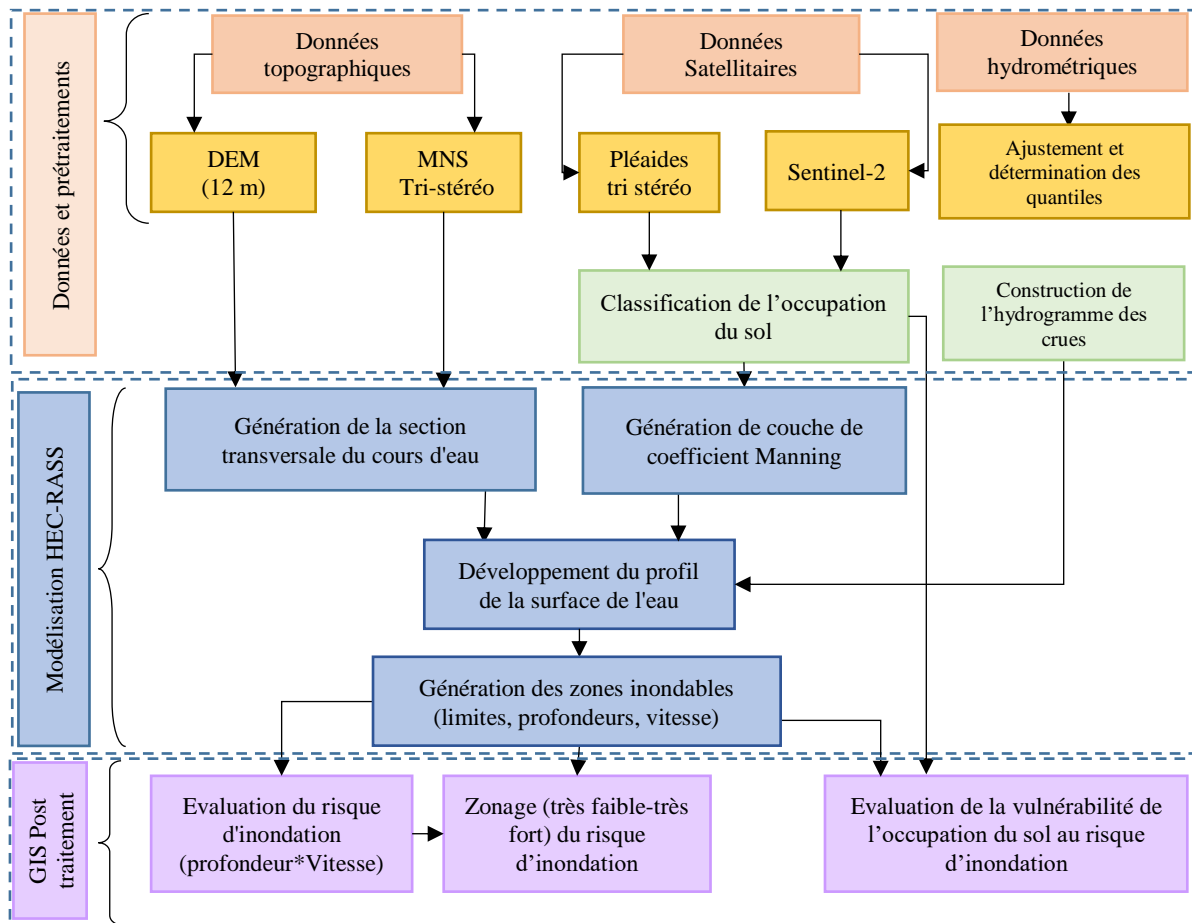


Figure V.1. L'organigramme général de la méthode de simulation hydraulique appliquée dans l'étude.

V.2.1. Classification de l'occupation du sol et assignement des valeurs de coefficient Manning de rugosité

Les cartes d'occupation du sol dérivées précédemment (chapitre IV) ont été utilisées comme base de données indispensable pour l'étape de la simulation hydraulique et pour évaluer des impacts sur la vulnérabilité aux inondations.

Notons que les cartes utilisées dans cette étape sont celles qui ont la meilleure précision avec deux bases de données de l'occupation du sol pour deux résolutions spatiales différentes, une qui est fournie par l'image Sentinel-2 (10 m) et l'autre par l'imagerie Pléaides THRS (2 m). L'objectif est d'évaluer l'impact de différentes sources des classifications de l'occupation du sol et leur contribution pour l'évaluation des risques d'inondation.

Par ailleurs, les classifications de l'occupation du sol ont été exploitées pour générer des couches de coefficient de rugosité Manning. Les valeurs de Manning déterminant la rugosité

de la surface et ont été attribuées en fonction des différentes catégories de l'occupation du sol, tels que classées par les images satellitaires.

Les classes en question sont principalement : eau, sols nus, constructions, terres agricoles, terres non agricoles, routes, jachère et forêts.

La détermination appropriée des valeurs de Manning prend en compte la présence de constructions, les zones nues et les zones agricoles ou occupées par la végétation afin de fournir une simulation plus réaliste de la genèse de l'écoulement en milieu inondable

Le travail consiste à associer des valeurs de rugosité à une partie de la classification obtenue précédemment couvrant le tronçon du cours d'eau d'intérêt.

V.2.2. Génération de modèle topographique

Le processus de la modélisation hydraulique nécessite comme entrée un modèle numérique de terrain permettant une représentation des cours d'eau et des plaines exposées aux inondations. Dans notre étude, deux types du modèle numérique de terrain sont acquises avec différentes résolutions spatiales.

Le MNS est généré à partir d'une image tri-stéréo avec une résolution spatiale très élevée (moins de 2 m) permettant de détecter le couvert végétal, les toits des bâtiments, les sols nus et le sol lorsqu'il n'y a rien d'autre au-dessus. Afin d'évaluer l'impact de la précision de la topographie du milieu urbain sur le processus de la simulation hydraulique, une étude comparative des modèles MNS tri-stéréo et MNT- 12 m de résolution spatiale a été préconisée.

Le système Pléiades offre la possibilité d'acquérir une imagerie stéréoscopique comprenant deux images à différence angulaire réglable (B/H), ainsi qu'une imagerie stéréoscopique avec une image quasi-verticale supplémentaire (triple stéréoscope), permettant ainsi à l'utilisateur d'avoir une vue d'ensemble de l'image avec son environnement stéréoscopique. Notons que, le rapport B/H est une information renseignant les conditions d'acquisition d'images satellites multistéréoscopiques. Ce rapport est calculé à partir de la comparaison de la distance parcourue par le satellite entre deux prises (B) et l'altitude à laquelle se place ce satellite (H). Par ailleurs, Les images Pléiades Tri-stéréo peuvent être utilisées des modèles 3D précises, comparées à celles créées à une base stéréo, car l'acquisition près du Nadir minimise le risque d'objets cachés manquants. Il est idéal pour les villes denses et les zones montagneuses (Airbus, 2022). Cela permet également de détecter la topographie des zones sensibles à accès difficile tels que les cours d'eau.

V.2.2.1. Calcul de modèle numérique d'élévation à partir d'images Pléiades tri-stéréo

Le système Pléiades permet d'acquérir des images en n-uplets stéréo, souvent une paire ou un triplet, avec n allant de 2 à 25. Chaque image est alors acquise sous un angle d'incidence et un azimut différent.

Pour le calcul de Modèle Numérique de Surface MNS, il est primordial de prendre en compte tout ou partie de l'image générée. L'acquisition d'image est faite donc depuis des angles de vue différents pour la même zone d'intérêt.

Cependant, plusieurs facteurs produisent une distorsion ou parallaxe entre les images tels que le relief, les différents angles de prises de vue, la courbure de la terre, l'emplacement du satellite et les mouvements de la caméra. Par conséquent, en tenant compte l'angle de l'élévation de l'image et du premier ordre de l'angle d'intersection, la distorsion est déterminée à partir des sous sections d'une image.

La génération des MNS est souvent accomplie par différents logiciels commerciaux de traitement d'images satellitaires stéréoscopiques (par exemple, PCI Geomatica, ERDAS) ou libres développés par des institutions publiques parmi lesquels *Ames Stereo Pipeline* de la NASA, MicMac de l'IGN, SETSM de l'Ohio State University ou S2P de l'ENS Cachan et du CNES (Deschamps-Berger et al., 2020). Dans ce travail, la génération de MNS a été effectuée en utilisant le service *DataTerra* de calcul à la demande DSM-OPT (*Digital Surface Models from Optical stereoscopic very-high resolution imagery*). Ce service a été opéré par le pôle ForM@Ter (Terre Solide) (www.poleterresolide.fr/le-service-dsm-opt/), en collaboration avec le pôle Theia (Surfaces Continentales) et le dispositif DINAMIS. Lors du choix des traitements radiométriques des images, de la détermination de leur position, du processus de corrélation et du filtrage des produits intermédiaires, le calcul de MNS tient en compte les particularités du terrain telles que la contraste, la pente et la rugosité. Cela s'avère très utile pour l'étude et la simulation des inondations. En outre, à l'aide de cet outil en ligne, nous avons procédé au calcul de en s'appuyant sur les paramètres suivants :

- Le type de paysage : littoral.
- Images d'entrée : le dossier de tri-stéréo d'images acquises contenant les images de différents angles de prise de vue
- Zone d'intérêt : comprenant la ville de Ténès (partie Nord de bassin versant étudié).
- Facteur de résolution de MNS : ici il a été choisi un facteur élevé pour générer des MNS à très haute résolution.

- Selon le choix de l'utilisateur : la création de l'ortho-images peut être individuelle ou mosaïque.
- La possibilité de génération de MNS en nuage de points selon les spécifiés de l'utilisateur
- Le recouvrement des surfaces en eaux : dans notre cas cette option a été choisi afin de générer la topographie précise de cours d'eau.
- En mode expert, des valeurs de facteur de régularisation, d'incertitude en Z, le seuil de la précision potentielle et le seuil des pixels décorrélés ont été définis d'une manière à minimiser les erreurs lors de la génération des MNS, d'où des petites valeurs ont été choisies pour les seuils d'erreurs.

En sortie de modèle, en plus du MNS généré, différents fichiers ont été créés, indiquant la précision du MNS créés en rapport aux scores de corrélation :

- MNS débruité : grille d'élévation débruitée en appliquant une minimisation de l'erreur quadratique moyenne sur une fenêtre glissante de 5 x 5.
- MNS débruité et filtré en élévation relative : grille d'élévation débruitée et filtrée sans données pour les pixels avec des scores de corrélation < 127
- MNS débruité et filtré en élévation absolue : grille MNS alignée dans les composantes horizontale et verticale sur une grille d'élévation absolue.
- MNS débruité en élévation relative dans un format de fichier de nuage de points.

Le MNS crée avec débruitage et filtration en élévation absolue a été utilisé pour la création de terrain topographique dans la simulation hydraulique avec le modèle HEC-RAS (Figure V.2).

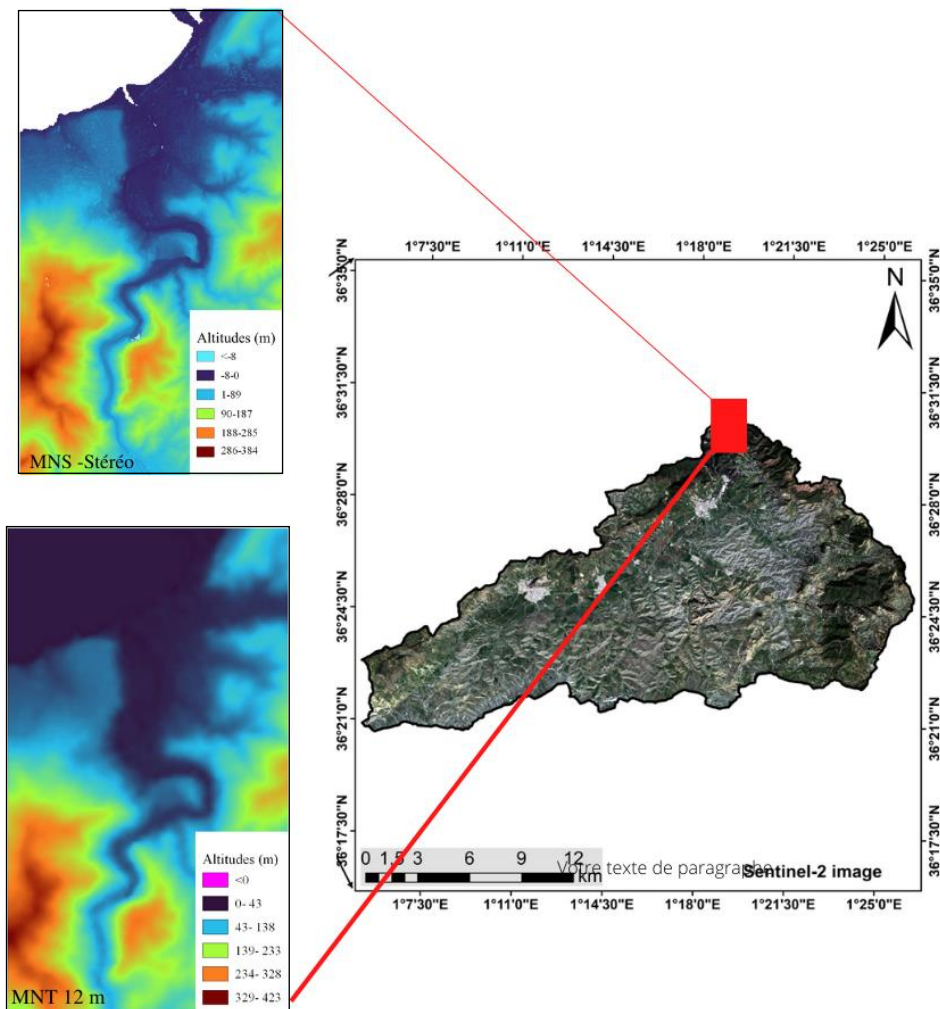


Figure V.2. MNT et MNS utilisées dans la simulation hydraulique.

V.2.3. Description du modèle utilisée pour la simulation hydraulique

Réalisé depuis 1995, la première version du logiciel de modélisation hydraulique HEC-RAS (*Hydrologic Engineering Centers - River Analysis System*), propose des codes de calculs qui permettent d'effectuer des calculs hydrauliques unidimensionnels (1D), bidimensionnels (2D), ou combinés 1D et 2D pour différents types de canaux naturels et construits.

Pour l'analyse des rivières, HEC-RAS possède de nombreuses capacités telles que : (1) le calcul du profil de la surface de l'eau en régime permanent, (2) la simulation de l'écoulement instationnaire, (3) le calcul du transport des sédiments à la frontière mobile et (4) l'analyse de

la qualité de l'eau. Un élément clé est que les quatre composants utilisent la même représentation géométrique des données et les mêmes concepts de calcul géométrique et hydraulique. En plus des quatre composants d'analyse de rivière, le système intègre plusieurs fonctions de conception hydraulique qui peuvent être invoquées une fois que les profils de base de la surface de l'eau sont calculés. Dans ce qui suit on s'intéresse au développement des profils de surfaces d'eau en régime permanent et transitoire.

▪ **Profils de la surface de l'eau en régime permanent :**

- Cette composante du système de modélisation est destinée à calculer les profils de la surface de l'eau pour un écoulement stable et graduellement varié.
- Le modèle peut analyser un seul tronçon de rivière, un système dendritique ou un réseau complet de canaux. La composante de l'écoulement permanent est capable de modéliser les profils de la surface de l'eau en régime sous-critique, supercritique et mixte.
- La procédure de calcul de base est basée sur la résolution de l'équation énergétique unidimensionnelle (équation V.12).
- Les pertes d'énergie sont évaluées par friction (équation de Manning) et contraction/dilatation (coefficient multiplié par le changement de la hauteur de vitesse).
- L'équation de quantité de mouvement est utilisée dans les situations où le profil de la surface de l'eau varie rapidement. Ces situations comprennent essentiellement le calcul du régime d'écoulement mixte (c'est-à-dire les sauts hydrauliques), l'hydraulique des ponts et l'évaluation des profils aux confluences des rivières (jonctions de cours d'eau). Par ailleurs, les effets de divers obstacles tels que les ponts, les ponceaux, les déversoirs, et autres structures dans la plaine d'inondation peuvent être pris en compte dans les calculs.
- Le système d'écoulement permanent est conçu pour être appliqué à la gestion des plaines inondables et aux études d'assurance contre les inondations afin d'évaluer les empiètements sur le canal de crue. Il permet également d'évaluer les changements de profils de la surface de l'eau dus à l'amélioration des canaux et des levées.

▪ **Simulation d'écoulement instationnaire (non permanent)**

- Dans ce cas, la résolution de l'équation d'écoulement non stable 1D a été adaptée du modèle de Dr. Robert L. Barkau's UNET model (Barkau, 1992 and HEC, 1997), développée principalement pour les calculs de régime d'écoulement sous-critique.
- Le solveur d'équation d'écoulement instationnaire 2D est intégré directement dans le moteur d'écoulement instationnaire HEC-RAS pour faciliter la modélisation combinée de la dynamique des fluides 1D et 2D.

- Les simulations hydrauliques pour les sections transversales, les ponts, les ponceaux et autres structures hydrauliques intégrées dans le module de la simulation d'écoulement permanent sont également intégrées au module d'écoulement non permanent pour analyser les zones de stockage d'eau, les zones d'écoulement 2D et les régions hydrauliques entre différents tronçons de rivière.

- **Équations des calculs de profil de base**

Les profils de surface de l'eau sont calculés d'une section transversale à l'autre en résolvant l'équation énergétique avec une procédure itérative appelée méthode par étapes standard. L'équation énergétique est écrite comme suit :

$$Z_2 + Y_2 + \frac{av_2V_2^2}{2g} = Z_1 + Y_1 + \frac{av_1V_1^2}{2g} + h_e \quad (\text{V.12})$$

Où :

Z_1, Z_2 : élévations des inversions du chenal principal

Y_1, Y_2 : profondeurs d'eau aux sections transversales

V_1, V_2 : vitesses moyennes (débit total / surface d'écoulement totale)

a_1, a_2 : coefficients de pondération de vitesse

g : accélération de gravité

h_e : perte d'énergie

L'équation de la perte de charge énergétique est donnée par la formule:

$$h_e = L\bar{S}_f + C \left| \frac{av_2V_2^2}{2g} - \frac{av_1V_1^2}{2g} \right| \quad (\text{V.13})$$

Où :

L : longueur de portée pondérée en sortie

\bar{S}_f : pente représentative du frottement entre deux sections

C : coefficient d'affaiblissement de dilatation ou de contraction.

La longueur d'atteinte pondérée en distance, L , est calculée par la formule suivante :

$$L = \frac{L_{lob} \overline{Q_{lob}} L_{ch} \overline{Q_{ch}} + L_{rob} \overline{Q_{rob}}}{\overline{Q_{lob}} + \overline{Q_{ch}} + \overline{Q_{rob}}} \quad (V.14)$$

Où :

L_{lob} , L_{ch} et L_{rob} sont les longueurs des sections transversales spécifiées pour l'écoulement, dans les zones d'ondulation gauche, principale et droite, respectivement.

$\overline{Q_{lob}}$, $\overline{Q_{ch}}$ et $\overline{Q_{rob}}$ sont les moyennes arithmétiques des flux entre les sections pour les zones de débordement gauche, principale et droite, respectivement.

Dans le cas d'un écoulement non permanent, l'équation du moment est appliquée par le module de calcul intégrée à HEC-RAS pour exprimer la conservation de la quantité de mouvement par formule est la suivante :

$$\sum F_x = \frac{d\overline{M}}{dt} \quad (V.13)$$

Les composantes de l'équation de l'énergie sont reportées dans le diagramme suivant (Figure V.3).




Figure V.3. Représentation des termes d'équation énergétique.

La détermination du débit total et du coefficient de débit par HEC-RAS se fait en subdivisant chaque section en trois parties: rive droite, rive gauche et canal. Le flux est ensuite calculé dans chaque section à l'aide de l'équation de Manning comme suit:

$$Q = K(S_f)^{0.5} \quad (V.14)$$

Où :

K: le moyen de transport (-).

S_f : la pente de frottement (-).

V.2.4. Création et simulation du modèle hydraulique

En se basant sur les quantiles déterminés et la probabilité de retour d'inondations dans la région étudiée, la simulation dans cette étude a été réalisée pour six périodes de retour : 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.

Pour la propagation des ondes en aval, l'écoulement mathématique unidimensionnel intégré avec modèle de HEC-RAS a été utilisé. Ce modèle est très recommandé pour les simulations d'inondation. Il permet de résoudre l'équation d'énergie avec toute facilité en termes de temps et d'espace.

Parallèlement, ce modèle permet de générer des caractéristiques hydrauliques avec une stabilité numérique optimale, telles que, les limites d'inondations, la profondeur d'eau et la vitesse de propagation d'onde.

Par ailleurs, à l'aide des modèles topographiques utilisés dans l'étude, la géométrie de la plaine a été créée comprenant les trois composantes essentielles : la ligne centrale du canal principal, les limites du lit mineur du canal principal (main channel banks), les limites du lit majeur (flow path) et les sections en travers (*cross-sections*).

En outre, à l'aide de l'outil « Terrain- add land cover map » disponible sous RAS Mapper, le fichier raster de l'occupation du sol a été intégré dans le modèle. A partir de ce fichier, une couche du coefficient de rugosité Manning a été créée en assignant des valeurs de ce dernier à chaque classe de l'occupation du sol.

Une fois la géométrie créée (Figure V.4), nous pouvons l'ouvrir et la visualiser à l'aide du module « Geometric data » qui permet de visualiser les sections en travers générées et l'attribution de la couche de Manning pour toutes les sections. Par ailleurs, la création de modèle conçu pour la simulation hydraulique a été entreprise à l'aide de l'outil « *Steady Flow Data* ». Pour ce travail de thèse, le modèle de l'écoulement permanent a été choisi. Dans cette phase, des profils d'eau ont été créés et correspondent aux six périodes de retour analysées dans l'étude. Ainsi, la création des profils d'eau en utilisant des modèles tel que HEC-RAS requièrent

les spécifications sur les conditions aux limites en amont et en aval de cours d'eau. Ces spécifications comportent principalement la hauteur critique et la pente normale.

La simulation hydraulique à travers l'outil « *Steady flow Analysis* » permet de modéliser les profils d'écoulement en régime d'écoulement fluvial, torrentiel ou mixte pour différents débits simultanés (USACE, 2016). Le lancement du calcul a permis de générer différentes couches caractéristiques pour chaque profil d'eau simulé. Ces couches de HEC-RAS peuvent être exportées et visualisées dans un environnement SIG. Ainsi, les résultats de simulation sous HEC-RAS sont exploités pour la création des cartes de l'aléa, de la vulnérabilité et de l'évaluation du risque d'inondation.

Ces analyses seront détaillées dans les sections suivantes puis procéder au calage du modèle, une étape indispensable pour confirmer la fiabilité de modèle créé.

Les modèles ont été calés avec une crue survenue en 2017 et à travers la variation des valeurs de coefficient de rugosité Manning appuyée par une comparaison de la ligne d'eau simulée avec celle observée. Les valeurs attribuées au coefficient de rugosité sont pour chaque classe d'occupation du sol.

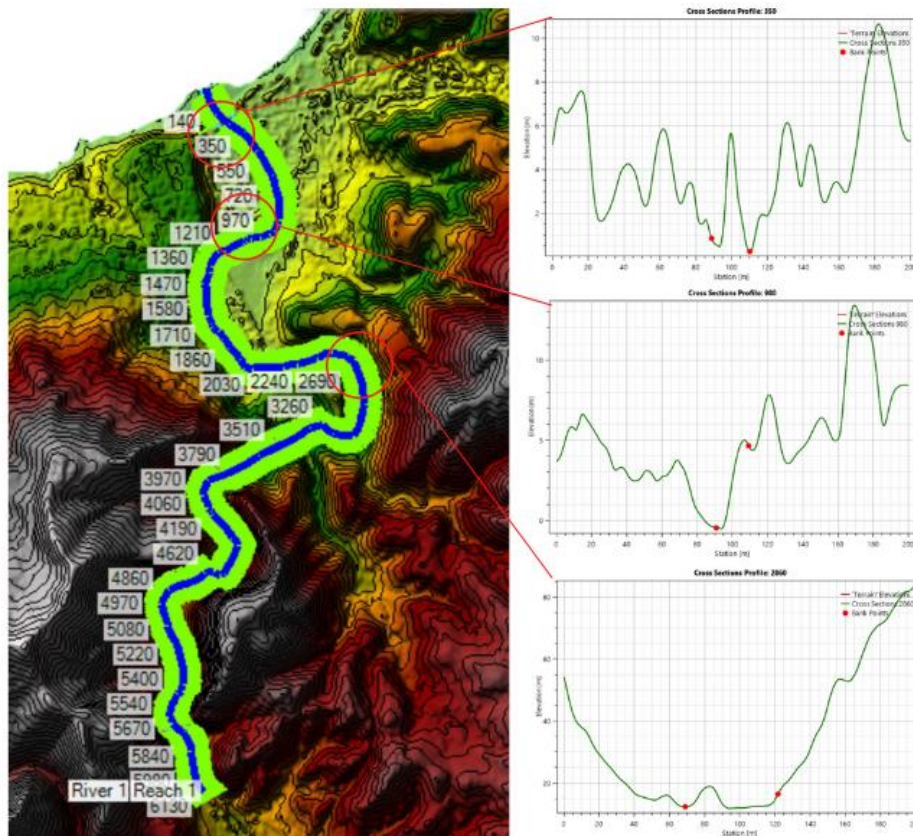


Figure V.4. Géométrie créé sous HEC-RAS.

V.2.5. Evaluation du risque d'inondation

En effet, le risque est défini avec ses deux composantes « aléa » et « vulnérabilité ». Par conséquence, l'évaluation de la vulnérabilité est assurée par l'exécution d'un modèle fondé sur la présence ou l'absence de l'inondation dans une classe spécifique de l'occupation du sol.

A partir des résultats de profondeur et de vitesse d'écoulement générés par le code de calcul HEC-RAS, sur la base des données fournies par les cartes de l'occupation du sol, un modèle spatial a été utilisé pour l'évaluation du risque avec ces deux composantes susnommées moyennant des traitements nécessaires, réalisés avec HEC-RAS et l'interface du module graphique personnalisée via un environnement de système d'information géographique (SIG).

V.2.5.1. Analyses d'aléa inondation

L'aspect aléa du risque d'inondation est souvent défini par les paramètres hydrauliques et hydrologiques. La fréquence d'une inondation est considérée comme un indicateur largement accepté pour l'estimation des risques d'inondation. En effet, pour la quantification du risque d'inondation et du potentiel de dommages, la profondeur d'eau est un paramètre déterminant. Par conséquent, le niveau de danger peut être défini par la combinaison des deux paramètres, à savoir, la profondeur de l'inondation et la vitesse d'écoulement (Kreibich et al. 2009; Psomiadis et al. 2021). Cela implique que la même inondation affectera une zone particulière avec les mêmes propriétés hydrauliques, quels que soient l'occupation et l'utilisation du sol. En ce sens, de multiples critères d'évaluation des dommages du risque d'inondation ont été développés, par exemple ceux proposés par l'American Society of Civil Engineers (ASCE, 1952) et du US Bureau of Reclamation (USBR) (USBR, 1988). Dans cette étude, le critère proposé par National Flood Risk Advisory Group (NFRAG) Committee (Smith et al., 2014) a été examiné et considère que dans l'étude de la gestion spécifique des plaines inondables ou de l'analyse de la gestion des urgences, il peut y avoir un besoin évident d'utiliser des seuils spécifiques en fonction de la profondeur (h) et la vitesse d'écoulement (V). Cependant, en particulier, dans une évaluation préliminaire des risques ou dans le cadre d'une analyse des contraintes, il existe également un besoin reconnu d'un ensemble combiné de courbes de vulnérabilité aux aléas, qui peut être utilisé comme une classification générale des risques d'inondation dans une plaine inondable. Ces courbes combinées d'aléa de crue fixent des seuils d'aléa qui se rapportent à la vulnérabilité de la communauté lorsqu'elle interagit avec l'évènement extrême (Smith et al., 2014). Les courbes combinées sont divisées en six classifications de danger qui se rapportent à des seuils de vulnérabilité spécifiques (Tableau V.3). L'application analytique de ce critère a été réalisé sous HEC-RAS à l'aide des outils spécifique de calcul de la quantité : profondeur x vitesse d'écoulement. Par ailleurs, la classification selon les seuils définis par ce critère est assurée à l'aide d'un algorithme proposé par le même groupe scientifique.

Tableau V.2. Courbes de risque combinées - seuils de vulnérabilité (d'après Smith et al, 2014).

Aléa classification	Descriptions
$h*v$	
H1 ≤ 0.3	Généralement sans danger pour les véhicules, les personnes et les bâtiments.
H2 ≤ 0.6	Non sécurisé pour les petits véhicules.
H3 ≤ 0.6	Non sécurisé pour les véhicules, les enfants et les personnes âgées.
H4 ≤ 1.0	Insécurité pour les véhicules et les personnes.
H5 ≤ 4.0	Insécurité pour les véhicules et les personnes. Tous les bâtiments sont vulnérables aux dommages structurels. Certains bâtiments moins robustes sont sujets à des défaillances.
H6 > 4.0	Insécurité pour les véhicules et les personnes. Tous les types de bâtiments sont considérés comme vulnérables aux défaillances.

h: profondeur, v : vitesse d'écoulement.

Ces classes d'aléa ont été reclassées en trois classes pour le zonage du risque d'inondation :

Faible-moyen : $h*v < 0.6 \text{ m}^2/\text{s}$

Moyen: $0.6 \text{ m}^2/\text{s} < h*v < 1 \text{ m}^2/\text{s}$

Fort –très fort : $h*v > 1 \text{ m}^2/\text{s}$

V.2.5.2. Analyses de la vulnérabilité aux inondations

La vulnérabilité aux inondations est affectée par les caractéristiques de l'occupation du sol des zones sujettes aux risques d'inondation. Autrement dit, une inondation ayant la même probabilité de dépassement aura différents niveaux de vulnérabilité selon les caractéristiques de l'occupation du sol et le degré de dommages.

L'analyse de la vulnérabilité consiste donc à identifier les zones d'occupation des sols sous l'influence potentielle d'une inondation de période de retour particulière. Pour cela, des cartes de vulnérabilité sont réalisées en découpant sur une carte d'occupation du sol les plaines inondables avec le fichier polygone définissant les limites d'inondation pour chacune des périodes de retour simulées. Ceci décrit l'aspect de vulnérabilité du risque d'inondation dans une zone particulière, c'est-à-dire la présence ou l'absence d'inondation pour une période de retour définie.

La zone d'occupation du sol touchée par chaque inondation a été reclassée pour déterminer la zone vulnérable totale.

V.2.5.3. Analyse du risque d'inondation

L'analyse des risques d'inondation comprend la combinaison des résultats de l'analyse de vulnérabilité et de l'analyse d'aléa. Elle est définie par la relation entre les classes de vulnérabilité de l'occupation des sols et les classes d'aléa de profondeur d'inondation et vitesse d'écoulement dans une zone particulière. Pour cela, les cartes d'aléa inondation préparées

pendant l'analyse des risques sont croisées avec les cartes de vulnérabilité de l'occupation des sols pour créer les cartes du risque d'inondation. Les tables d'attributs résultantes sont reclassées pour développer la relation entre les deux types de risques.

Cette analyse représente donc le potentiel du risque global d'inondation en fonction de classes de vulnérabilité de l'occupation du sol et de classes d'aléa de profondeur d'eau et vitesse d'écoulement.

V.3. Résultats et discussions

Dans cette partie, nous présentons les résultats de l'application d'un modèle hydraulique 1D qui intègre les données spatiales, principalement les cartes produites de l'occupation du sol, les données topographiques issues des modèles topographiques de surface et hydrauliques pour la cartographie des zones inondables et l'évaluation du risque globale d'inondation. L'Oued Allala a été choisi pour l'implémentation de la méthodologie proposée. Ce site a été sélectionné en raison de l'exposition de sa plaine au risque d'inondation, comprenant en particulier la région côtière de la ville de Ténès, où la densité urbaine est grande près des rives du cours d'eau. Les données satellitaires utilisées pour l'implémentation des méthodes proposées sont l'image Pléiades tri-stéréo qui a permis de générer un modèle numérique de surface (MNS) à très haute résolution, un MNT de 12 m pour la comparaison et les résultats de la cartographie de l'occupation du sol de la région étudiée à l'issue de l'application de l'approche décrite précédemment (cf. chapitre VI). En ce qui concerne les données hydrologiques, une série des débits maxima journaliers enregistrés à la station hydrométrique de Sidi Akkacha sur une période de 46 ans a été utilisée pour la détermination des quantiles et la construction de l'hydrogramme exploités pour la simulation hydraulique. La cartographie des zones inondables et l'évaluation du risque d'inondation sont effectuées pour six périodes de retour : 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans par le biais du logiciel HEC-RAS. Les résultats décrits ici comprennent essentiellement l'analyse fréquentielle et la détermination des quantiles, calcul et construction de l'hydrogramme des crues, simulation hydraulique et détermination des paramètres hydrauliques d'inondation, l'analyse d'aléa et l'analyse de vulnérabilité des classes d'occupation du sol au risque d'inondation.

V.3.1. Résultats d'ajustement aux lois de distribution

Pour l'ajustement de la série hydrométrique de la station Sidi Akkacha, sur une période de 46 ans, quatre modèles d'ajustement ont été appliqués. Il s'agit des lois : Gumbel, Log-normale, Log-normale à trois paramètres et Log-Pearson à trois paramètres. L'analyse fréquentielle de la série hydrométrique à travers ces lois a permis de déterminer les quantiles correspondants aux périodes de retour choisies pour l'étude, à savoir 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans. Les graphes d'ajustement ainsi que les débits maxima calculés par chaque modèle sont rapportés respectivement dans la Figure V.5 et le Tableau V.3.




Figure V.5. Résultats d'ajustement de la série hydrométrique de la station Sidi Akkacha par les lois de distribution ; Gumbel, Log-normale, Log-normale III et Log-Pearson III.

Tableau V.3. Résultats de calcul de quantiles.

Lois de distribution	Débit max (m ³ /s)					
	2 ans	5 ans	10 ans	20 ans	50 ans	100 ans
Gumbel	121	223	291	356	441	504
Log Normale à deux paramètres	96.9	207	307	426	615	786
Log Normale à trois paramètres	90.8	204	319	463	708	941
Log-Pearson à trois paramètres	88.9	196	312	470	770	1090

A partir de la visualisation des graphes, nous pouvons constater que les observations au niveau de la station hydrométrique s'ajustent aux lois de distributions Log-normale, Log-normale III et Log-Pearson III. En effet, la majorité des valeurs observées se situent à l'intérieur des intervalles de confiance de ces modèles. Tandis que, les valeurs des débits maximums sont raisonnablement distribuées à l'extérieur de l'intervalle de confiance de la loi Gumbel (figure V.5). Par une comparaison des résultats de calcul des quantiles, les valeurs de débits maxima sont véritablement différentes d'une loi à une autre avec un grand écart, à l'exception des lois Log Normale à trois paramètres et Log-Pearson à trois paramètres où il y n'a pas un grand écart entre elles. Pour le choix de la meilleure loi de distribution, en plus de la comparaison graphique (Figure V.6), il est indispensable d'établir les critères d'ajustement. Les résultats de calcul des critères d'ajustement BIC et AIC ont montré que les valeurs faibles sont obtenues par le modèle Log-Pearson à trois paramètres (Tableau V.4).

Il y a lieu de rappeler que les données hydrométriques s'ajustent raisonnablement à la loi Log-Pearson à trois paramètres et les valeurs de probabilités d'occurrence des inondations et leurs périodes de retour obtenues par ce modèle sont retenues pour les analyses hydrauliques et le calcul de l'hydrogramme de crues (Figure V.7).




Figure V.6. Comparaison graphique entre les lois d'ajustement.

Tableau V.4. Résultats de calcul des critères AIC et BIC pour les différents modèles de distributions.

Modèle	P(Mi/x)	BIC	AIC
Gumbel	0.0	581.5	577.8
Log Normale à deux paramètres	40.3	548.3	544.6
Log Normale à trois paramètres	24.6	549.2	543.8
Log-Pearson à trois paramètres	35.1	548.5	543.0

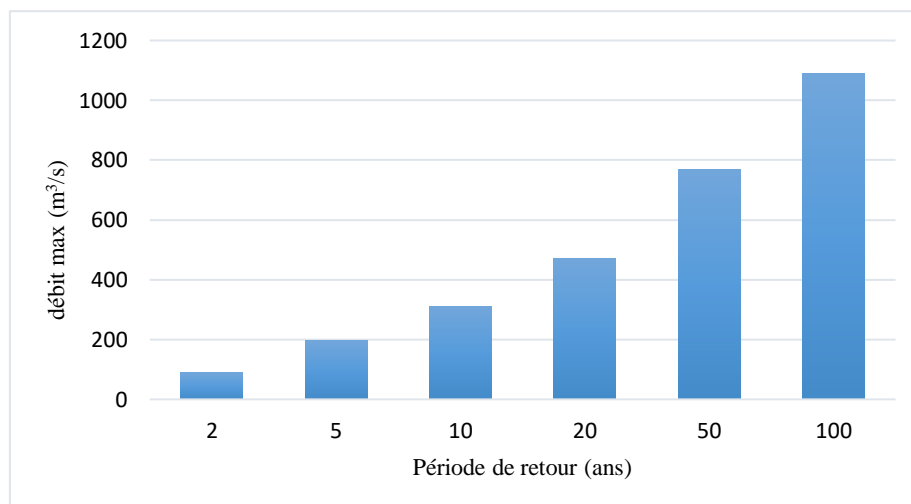


Figure V.7. Débits maxima correspondants aux périodes de retour étudiées.

V.3.2. Results de calcul de l'hydrogramme des crues pour les périodes de retour

L'hydrogramme des crues a été construit à partir des résultats de calcul des débits maxima par la loi adéquate à la série hydrométrique et le temps de concentration du bassin versant d'Oued Allala. De ce fait, la valeur $T_c = 8$ h a été retenue pour le calcul des temps de bases, de décrue et ensuite la construction de l'hydrogramme des crues pour les six périodes de retour, selon la méthode de Sokolovsky (Figure V.8).




Figure V.8. Hydrogrammes de crue à la station hydrométrique de Sidi Akkacha pour les différentes périodes de retour : 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.

Les débits maxima retenus pour la simulation hydraulique sous HEC-RAS sont : 88,9 m³/s, 196 m³/s, 312 m³/s, 470 m³/s, 770 m³/s et 1090 m³/s correspondants respectivement aux périodes de retour 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.

V.3.3. Résultats de la simulation hydraulique et l'évaluation du risque d'inondation

Dans cette section, sont présentes les résultats de la simulation hydrauliques effectuée sous HEC-RAS et la production des cartes des caractéristiques hydrauliques, de l'aléa et de la vulnérabilité du risque d'inondation.

Deux modèles de simulation hydraulique sous HEC-RAS ont été créés à partir de deux modèles numériques d'élévation. Le premier provient d'une image Pléiades tri-stéréo à THRS (MNS) et l'autre à partir d'un modèle à 12 m de résolution. Les modèles ont été calés avec une crue de

l'année 2017 à travers la variation des valeurs de coefficient de rugosité Manning et la comparaison de la ligne d'eau simulée avec celle observée.

Les valeurs attribuées au coefficient de rugosité pour chaque classe d'occupation du sol sont rapportées dans le tableau V.5.

Tableau V.5. Valeurs de coefficient de rugosité Manning en fonction de classes de l'occupation du sol.

Classes d'occupation du sol	Eau	Constructions	Routes	Sols nus	Terres agricoles	Terres non agricoles	Forêts	Végétation Moyenne
Coefficient Manning	0.30	0.025	0.013	0.035	0.035	0.035	0.2	0.2

Ainsi, le tableau suivant (tableau V.6) rapporte les résultats de comparaison entre la ligne d'eau simulée et observée. Les résultats possèdent une corrélation significative entre la ligne d'eau simulée pour les deux modèles topographiques par et la ligne d'eau observée avec des valeurs de coefficient de détermination environ 0,99 et 0,98 pour le MNS tri stéréo et le MNT (12m).

Tableau V.6. Résultats de comparaison entre la ligne d'eau observée et la ligne d'eau simulée et de calcul de coefficient de détermination.

Station (m)	3570	2860	1950	1450	750	350	150
Ligne d'eau observée (m)	22,7	17,22	13,1	7,26	5,9	6,44	5,8
Ligne d'eau simulée (MNS tri-stéréo) (m)	22,06	16,03	9,98	7,81	6,34	4,85	2,85
Ligne d'eau simulée (MNT 12 m) (m)	23,11	17,16	13,44	8,61	6,83	5,74	5,59
Coefficient de détermination R ²	MNS tri stéréo			MNT (12 m)			
	0,99			0,98			

V.3.3.1. Résultats de simulation hydraulique et détermination des paramètres caractéristiques d'inondation

La simulation des différents scénarios de récurrence des inondations par le modèle HEC-RAS a permis d'extraire les caractéristiques d'inondation prédites pour les deux types de modèles topographiques utilisés en amont de la constitution de modèles de simulation. Les paramètres

les plus pertinents qui peuvent caractériser et quantifier l'ampleur de l'aléa sont les profondeurs d'eau maximales, les vitesses d'écoulement et les limites spatiales d'inondations.

Les figures V.9, V.10 et V.11, représentent la profondeur d'eau maximale, la vitesse d'écoulement et les limites spatiales de l'inondation simulées en fonction de MNS tri-stéréo, pour les six périodes de retour étudiées.

De même, les figures V.12, V.13 et V.14 illustrent, la vitesse d'écoulement, la profondeur d'eau maximale et les limites spatiales de l'inondation simulées en fonction de MNT (12 m).




Figure V.9. Profondeurs d'eau simulées par MNS tri-stéréo pour différentes périodes de retour: 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.




Figure V.10. Vitesses d'écoulement simulées par MNS tri-stéréo pour différentes périodes de retour: 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.




Figure V.11. Limites spatiales d'inondation simulées par MNS tri-stéréo pour différentes périodes de retour : 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.

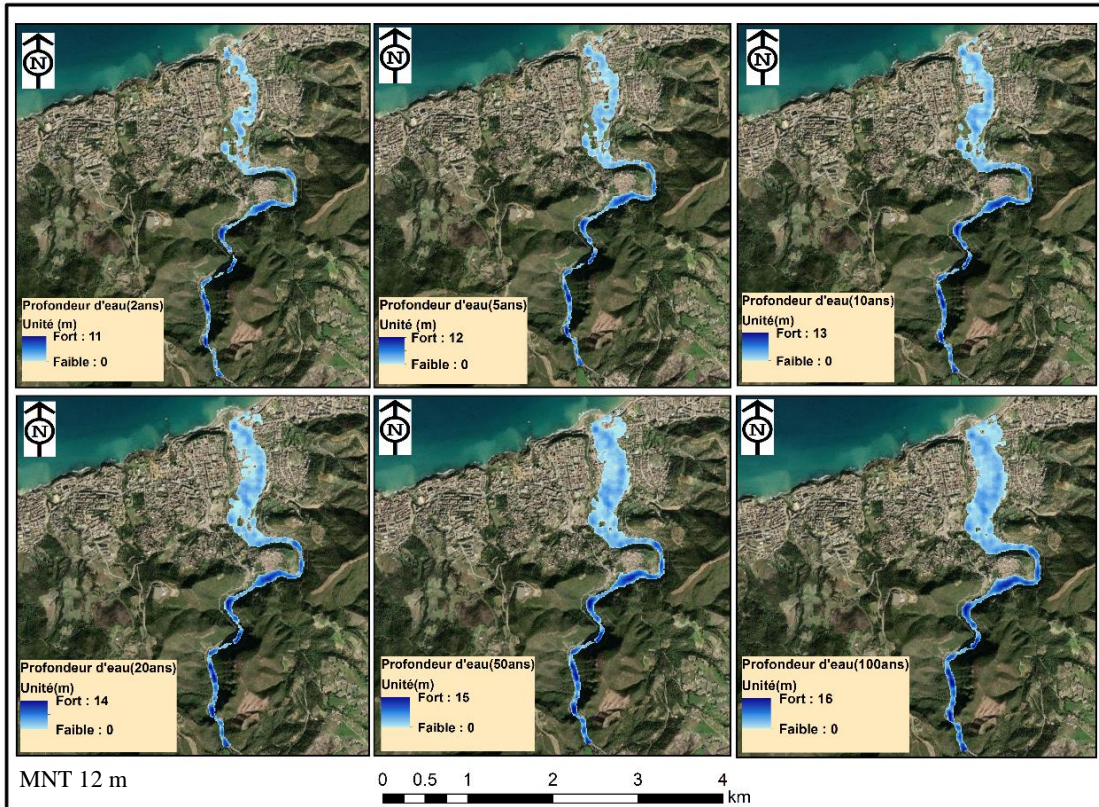


Figure V.13. Profondeurs d'eau simulées par MNT (12 m) pour différentes périodes de retour: 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.

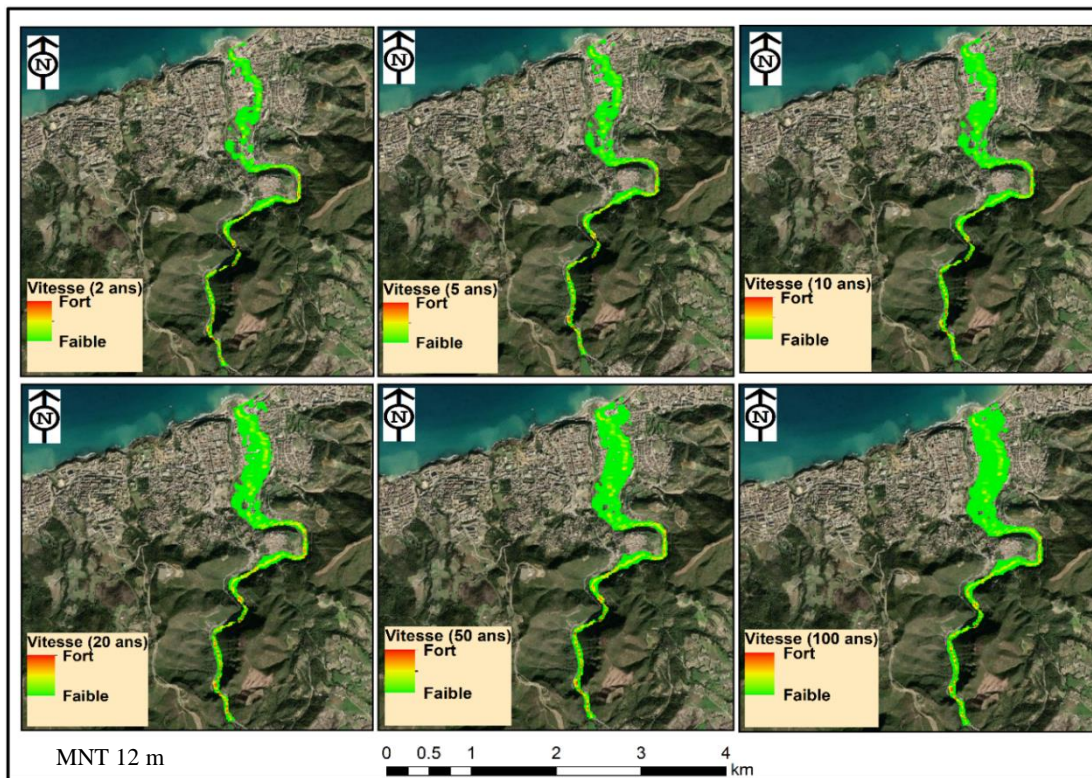


Figure V.12. Vitesses d'écoulement simulées par MNT (12 m) pour différentes périodes de retour: 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.




Figure V.14. Limites spatiales d'inondation simulées par MNT (12 m) pour différentes périodes de retour: 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.

L'examen visuel des cartes produites par les deux modèles confirme les résultats statistiques des simulations, où il y a des différences remarquables entre les deux scénarios de simulation notamment en ce qui concerne les limites spatiales de l'inondation et les champs spatiales des profondeurs d'eau. En fait, le MNS tri-stéréo tient compte des élévations surfaciques des infrastructures, bâtiments, ponts et également des surfaces végétales (telles que la végétation moyenne et les forêts).

En conséquence, la géométrie créée à travers ce modèle était raisonnable, de ce fait, ces champs topographiques sont explicitement apparus dans les cartes finales comme des obstacles d'écoulements, notamment dans le cas où leur élévation est grande (par exemple les bâtiments ou les arbres longs). Ce constat n'est pas le même pour le MNT (12 m), qui ne considère que le terrain naturel et non pas les autres champs surfaciques, y compris les infrastructures, les bâtiments et les ponts.

Les profondeurs d'eau augmentent d'amont en aval et les variations sont différentes en comparant le canal principal d'écoulement et les plaines inondables. La partie amont (la plus proche à la cote) est la plus vulnérable au risque d'inondation en raison de la présence de

bâtiments, de constructions, d'infrastructures et de routes, les résultats des profondeurs d'eau simulées sont reportées dans le tableau V.7.

Tableau V.7. Profondeurs d'eau simulées.

		Profondeurs d'écoulements (m)					
		2 ans	5 ans	10 ans	20 ans	50 ans	100 ans
MNS tri-stéréo	Canal principal	1,59 à 5,7	2,15 à 6,4	1,5 à 6,9	1,76 à 7,09	2,83 à 8,1	3,50 à 9
	Plaine inondable	0 à 0,81	0 à 1,17	0 à 0,16	0 à 1,76	0 à 2,87	0 à 3,1
MNT (12 m)	Canal principal	2 à 5,8	2,3 à 6,7	3,1 à 7,1	3,1 à 8,3	3,8 à 9,9	4,1 à 10,3
	Plaine inondable	0 à 0,86	0 à 1,13	0 à 1,46	0 à 3,17	0 à 3,7	0 à 3,90

Les vitesses d'écoulement sont également un paramètre important qui peut décrire l'évènement simulé. En tenant compte des résultats de simulation par les deux modèles topographiques, les résultats de simulation des vitesses d'écoulement sont reportés dans le tableau V.8.

Tableau V.8. Vitesses d'écoulements simulées.

		Vitesses d'écoulements (m/s)					
		2 ans	5 ans	10 ans	20 ans	50 ans	100 ans
MNS tri-stéréo		0 à 1,5	0,11 à 2,5	0,2 à 2,9	0,28 à 3,50	0,3 à 3,90	0,4 à 4,3
MNT (12 m)		0,14 à 2,8	0,29 à 3,07	0,43 à 3,7	0,63 à 4,16	0,87 à 4,66	0,59 à 5,83

Pour mieux visualiser les résultats de simulations par rapport à la crue de 2017, des aperçus de quelques coupes transversales sont montrés dans les figures (V.15- V.18).

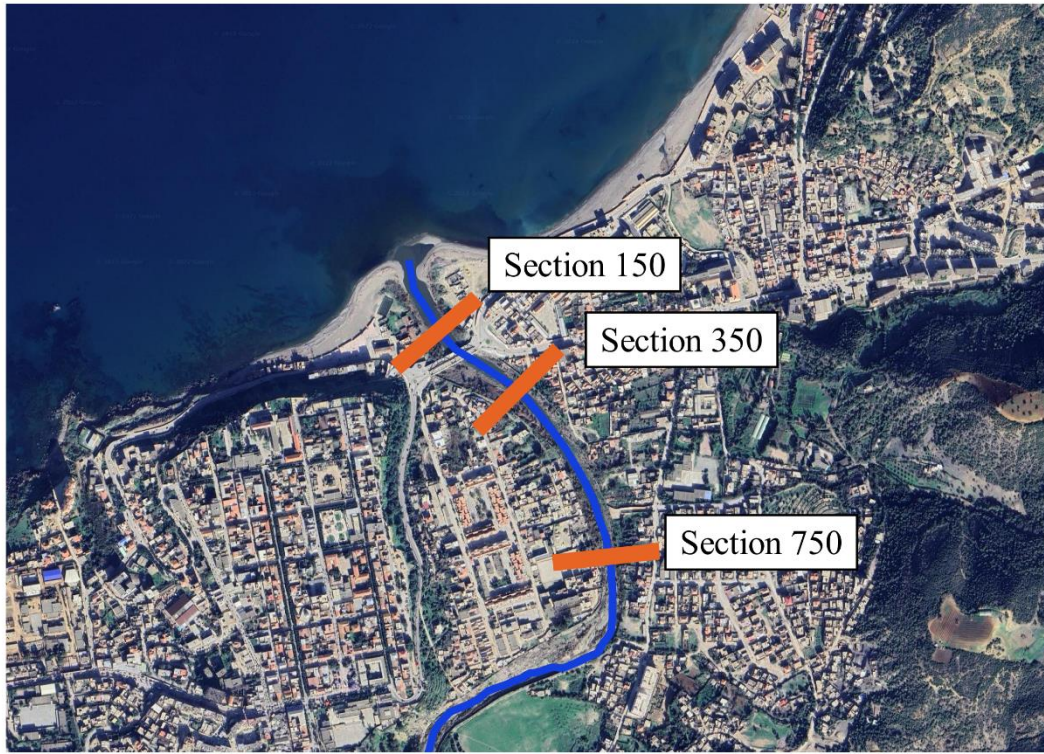


Figure V.15. Localisation des sections transversales.




Figure V.16. Ligne d'eau observée (cruce 2017) et simulée (période de retour centennale) à la station transversale 150.

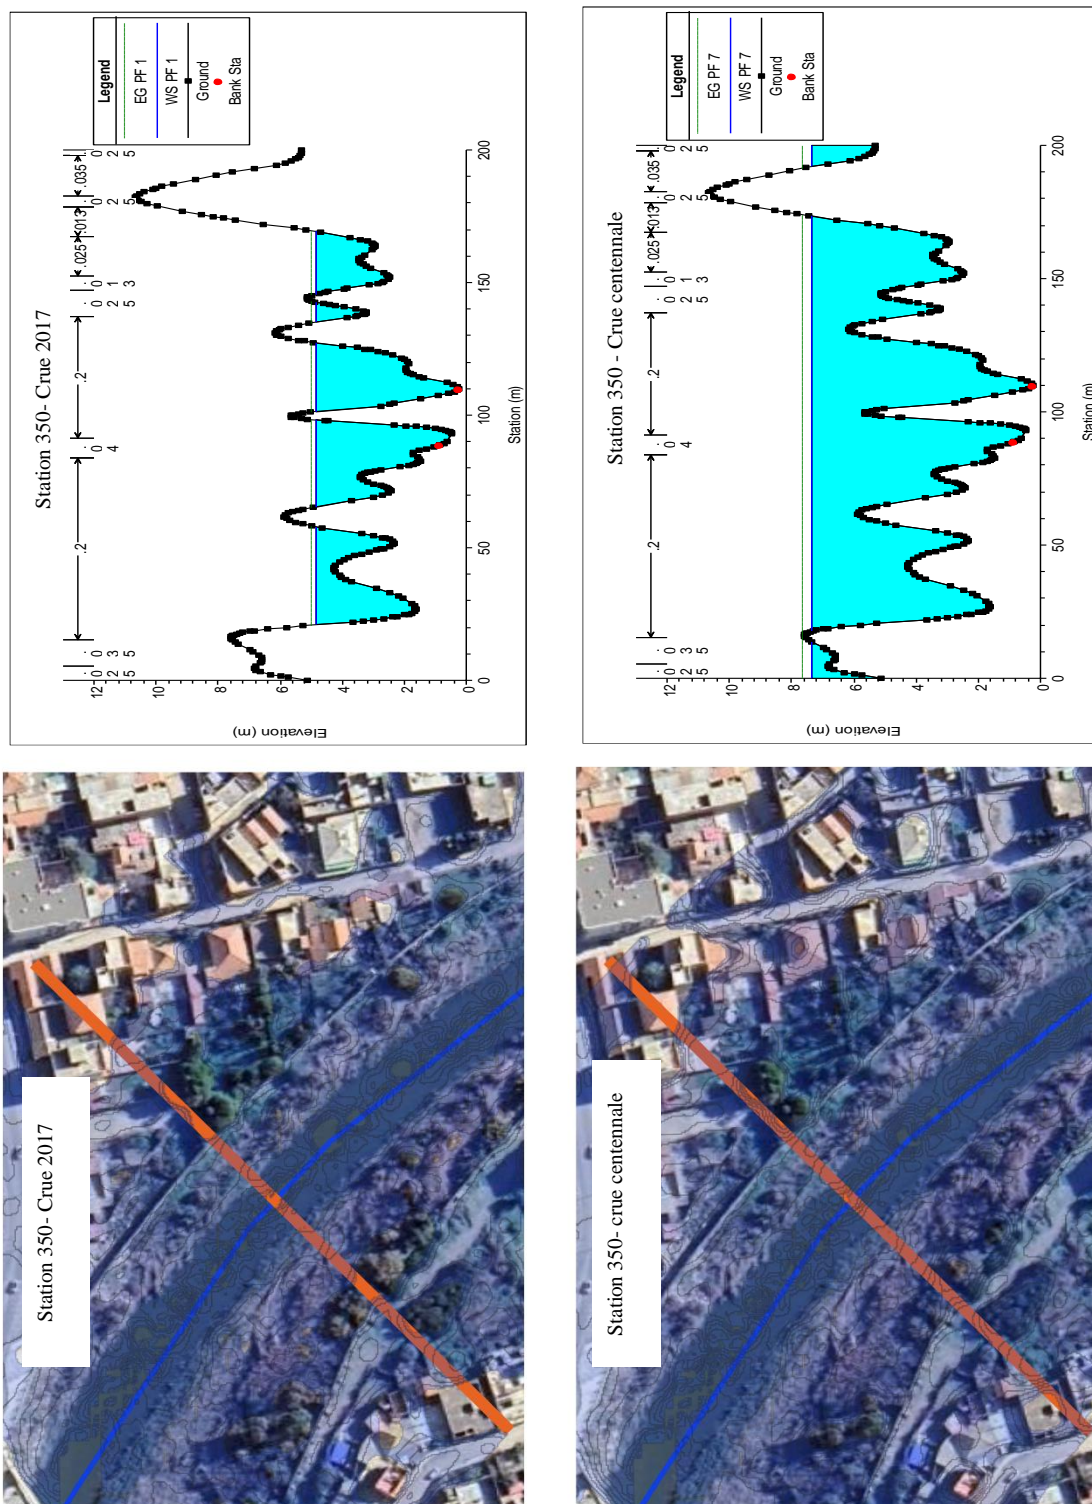


Figure V.17. Ligne d'eau observée (crue 2017) et simulée (période de retour centennale) à la station transversale 350.




Figure V.18. Ligne d'eau observée (crue 2017) et simulée (période de retour centennale) à la station transversale 750.

V.3.3.2. Résultats d'analyse de l'aléa inondation

Les analyses du risque d'aléa d'inondation sont établies pour les deux modèles MNS tri-stéréo et MNT (12 m) exploités pour la constitution des modèles de simulation. Ainsi, les cartes d'aléa sont produites à partir de résultats de profondeurs d'eau et des vitesses d'écoulement. Dans un premier temps et selon l'approche de (Smith et al., 2014), six classes ont été identifiées. Ensuite, ces classes ont été reclassifiées en trois classes pour mieux représenter les résultats selon trois degrés du risque (faible-moyen 0- 0,6, moyen et fort 0,6 -1 et > 1).

Les cartes des risques d'inondation pour les six scénarios de périodes de récurrence d'inondation générées à partir du modèle HEC-RAS sont exposées dans les figures V.19 et V.20 pour ce qui modèle MNS tri-stéréo et les figures V.22 et V.23 pour le MNT-12 m.




Figure V.19. Cartes d'aléa inondation (MNS tri-stéréo) selon la classification (Smith et al., 2014) .

En examinant les résultats qui figurent dans ces cartes, les zones susceptibles d'être inondées sont principalement situées près de la rivière, et s'étendent vers la plaine inondable du bassin versant de l'Oued Allala. Ces zones sont fréquemment caractérisées par la présence des

infrastructures et des constructions en raison de la croissance de la population. Cette concentration urbaine rend ces zones les plus critiques et par conséquent, les plus vulnérables au risque d'inondation. Les résultats de cette analyse sont essentiels pour réduire et atténuer l'impact des risques d'inondation dans les différentes parcelles en milieu urbain situées sur le bassin versant de la zone d'étude.




Figure V. 20. Cartes d'aléa inondation reclassifiées (MNS tri-stéréo).




Figure V.21. Cartes d'aléa inondation (MNT 12m) selon la classification (Smith et al., 2014).




Figure V.22. Cartes d'aléa inondation reclassifiées (MNT 12 m).

V.3.3.3. Analyse de la vulnérabilité aux inondations

La combinaison des résultats de la modélisation hydraulique avec les cartes de l'occupation du sol de haute précision ont permis d'analyser et d'évaluer l'exposition ou la vulnérabilité de la plaine inondable. Les cartes de classes d'occupation du sol inondées ainsi la vulnérabilité en fonction de ses classes produites à partir du MNS tri-stéréo et MNT (12 m) sont exposées dans les figures V.23 –V.26.

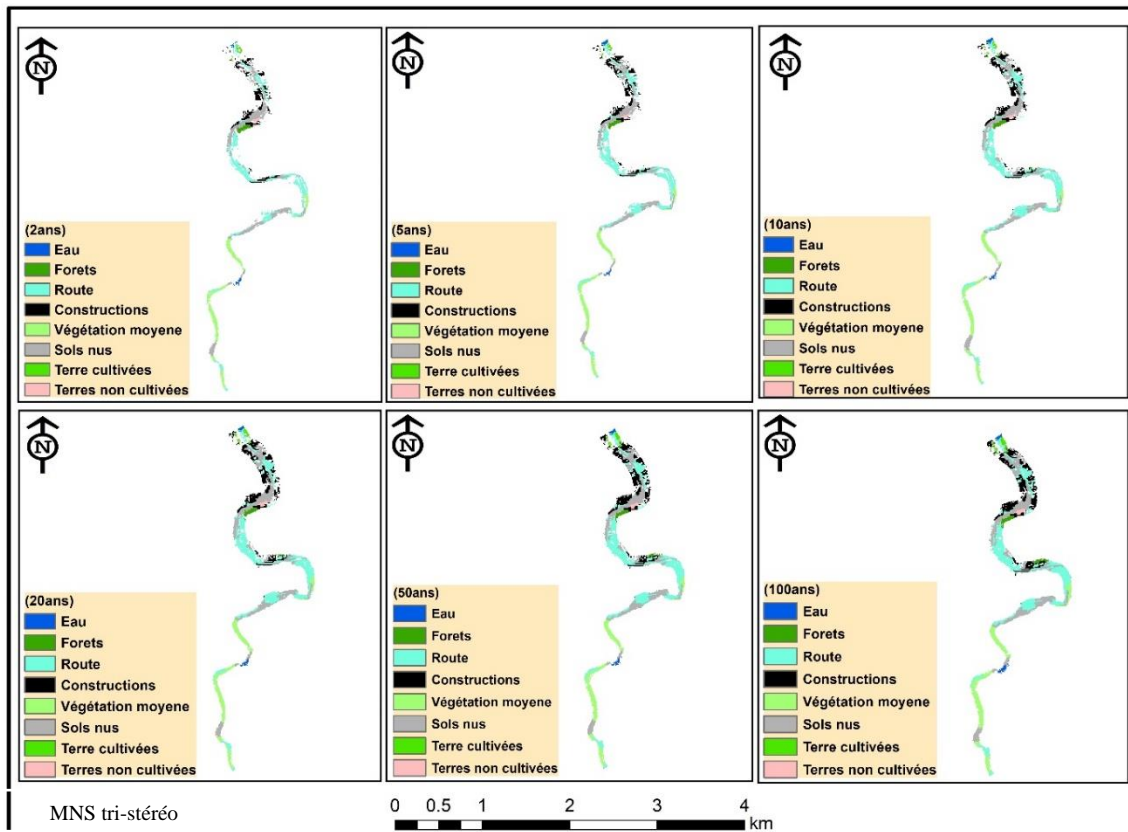


Figure V.23. Classes d'occupation du sol inondées (MNS tri-stéréo).




Figure V. 24. Cartes de vulnérabilité au risque d'inondation (MNS tri-stéréo).

Tableau V.9. Zones inondées prédites (MNS tri-stéréo) pour les différents types d'occupation du sol dans la zone affectée par les inondations.

Classes	Superficies inondées (ha)					
	2 (ans)	5 (ans)	10 (ans)	20 (ans)	50 (ans)	100 (ans)
Eau	0,32	0,4	0,47	0,5	0,57	0,69
Forêts	0,83	0,68	0,73	0,8	1,02	1,25
Routes	9,43	12,83	14,59	15,66	17,07	17,79
Constructions	4,5	5,63	6,85	7,87	9,16	9,96
Végétation moyenne	5,01	5,41	5,78	6,15	6,9	7,68
Sols nus	9,52	11,38	12,38	13,43	14,64	15,31
Terres agricoles	0,32	0,4	0,41	0,56	0,82	0,91
Terres non agricoles	0,38	0,36	0,44	0,45	0,47	0,5
Total	30,31	37,09	41,65	45,42	50,65	54,09

Pour la simulation avec MNS tri-stéréo l'analyse hydraulique a contribué au total de 30,31, 37,09, 41,65, 45,42, 50,65 et 54,09 ha de superficies inondées dans le site étudié, correspondantes respectivement aux périodes de retour 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.

En effet, les différentes classes d'occupation du sol affectées par les inondations, y compris l'eau, les forêts, les constructions, les routes, la végétation moyenne, les terres agricoles, les sols nus et les terres non agricoles sont montrées dans le tableau V.9 pour les six périodes de retour.

Pour le scénario de récurrence d'inondation de 2 ans, globalement, les sols nus, les routes et la végétation moyenne sont les classes les plus exposées au risque d'inondation avec respectivement, 9,52 ha, 9,43 ha et 5,01 ha de superficies inondées.

La même répartition des superficies inondables est constatée pour le scénario de 5 ans, les routes et les sols nus étaient également les plus vulnérables au risque avec plus de 12,83 ha et 11,38 ha ce qui signifie plus de 34,6 % et 31,9 % respectivement, de la totalité de superficie inondée. Néanmoins, pour la période de retour 10 ans, les classes (routes, constructions et sols nus) étaient les plus sujettes aux risques avec plus de 14,59 ha ; 12,38 ha et 6,85 ha, ce qui représente, 35 %, 29,7 % et 14,4 % de la superficie totale inondée.

Parallèlement pour la période de retour de 20 ans, les mêmes classes étaient les plus touchées par les inondations avec plus de 15,66, 13,43 ha équivalents à 34,47 %, 29,7 % et 17,3 % de la superficie inondée. Ce résultat signifie que la superficie des constructions inondées augmente avec l'augmentation de la période de retour.

En ce qui concerne le scénario des 50 ans, de la même manière qu'à 10 ans et 20 ans, les classes routes, constructions et sols nus étaient les plus touchées par les inondations selon le modèle simulé avec, respectivement, 17,07 ha, 14,64 ha et 9,16 ha de surfaces inondées, équivalents à 33,7 %, 28,3 % et 18,1 % de la superficie totale affectée par les inondations. Pour le dernier scénario (100 ans), plus de 17,79, 15,31 et 9,96 ha de routes, sols nus et construction sont inondés ce qui représente 32,9 %, 28,9 % et 18,4 % de la superficie totale inondée.

Ces résultats montrent que plus la période de retour est longue, plus la plaine est plus vulnérable aux inondations et par conséquent les zones inondées sont grandes en termes de superficie.

Tableau V. 10. Évaluation du risque à l'inondation en fonction de la superficie des différents catégories d'occupation du sol (MNS tri-stéréo).

Classes du risque	Catégories d'occupation du sol inondées (ha)										
		Eau	Forêts	Routes	Constructions	Végétation moyenne	Sols nus	Terres agricoles	Terres non agricoles	Total/ classe du risque	Total
2 ans	< 0,6	0,04	0,02	0,92	0,39	0,14	0,34	0,06	0,02	1,93	30,31
	0,6 - 1	0,03	0,29	2,43	1,29	0,60	1,30	0,07	0,09	6,1	
	>1	0,27	0,41	6,18	2,77	4,33	7,82	0,20	0,30	22,28	
5 ans	< 0,6	0,08	0,02	0,73	0,49	0,07	0,46	0,06	0,00	1,91	37,09
	0,6 - 1	0,07	0,19	2,99	1,30	0,38	1,36	0,06	0,07	6,42	
	>1	0,26	0,48	9,19	3,96	5,02	9,33	0,23	0,29	28,76	
10 ans	< 0,6	0,02	0,00	0,34	0,34	0,05	0,35	0,05	0,04	1,19	41,65
	0,6 - 1	0,15	0,09	2,15	1,20	0,19	1,19	0,11	0,02	5,1	
	>1	0,32	0,65	12,06	5,25	5,54	10,89	0,28	0,37	35,36	
20 ans	< 0,6	0,00	0,03	0,37	0,45	0,03	0,13	0,06	0,00	1,07	45,42
	0,6 - 1	0,13	0,03	1,31	1,09	0,23	1,06	0,17	0,05	4,07	
	>1	0,40	0,76	13,96	6,24	5,86	12,26	0,39	0,41	40,28	
50 ans	< 0,6	0,00	0,02	0,14	0,38	0,12	0,22	0,04	0,00	0,92	50,65
	0,6 - 1	0,03	0,17	1,02	1,13	0,50	0,74	0,21	0,01	3,81	
	>1	0,54	0,84	15,88	7,72	6,33	13,58	0,56	0,47	45,92	
100 ans	< 0,6	0,00	0,00	0,13	0,22	0,11	0,19	0,02	0,00	0,67	54,09
	0,6 - 1	0,01	0,10	0,63	0,72	0,36	0,53	0,17	0,00	2,52	
	>1	0,68	1,14	16,96	9,06	7,25	14,56	0,74	0,51	50,9	

Par ailleurs, pour la simulation avec MNT (12m), l'analyse hydraulique a contribué au total de 35,71, 45,56, 51,81, 60,61, 70,40 et 76,40 ha de superficies inondées dans le site étudié, correspondantes respectivement aux périodes de retour 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans.

Le tableau V.11 montre les différentes classes d'occupation du sol affectées par les inondations, y compris l'eau, les forêts, les constructions, les routes, la végétation moyenne, les terres agricoles, les sols nus et les terres non agricoles pour les six périodes de retour. Pour le scénario de récurrence d'inondation de 2 ans, globalement, les sols nus, les constructions et les routes

sont les classes les plus exposées au risque d'inondation avec, respectivement, 11,02 ha, 6,06 ha et 9,05 ha de superficies inondées.

Pour le scénario de 5 ans, les routes, les constructions et les sols nus étaient également les plus vulnérables au risque avec plus de 10,95 ha, 9,69 ha et 13,29 ha, ce qui signifie plus de 24 %, 21,3 % et 29,2 %, respectivement, par rapport à la totalité de la superficie inondée. Parallèlement, pour la période de retour 10 ans, les mêmes classes (routes, constructions et sols nus) étaient les plus sujettes aux risques avec plus de 12,42 ha, 11,73 ha et 14,60 ha, ce qui signifie, 24 %, 22,6 % et 28,2 % par rapport à la superficie totale inondée. A l'égard de la période de retour de 20 ans, la classe constructions était la plus touchée par les inondations avec plus de 16,20 ha, équivalent à 26,7 % de la superficie inondée. Ce résultat montre que les constructions inondées sont augmentées avec 4,1 % en comparaison avec le scénario de 10 ans. En ce qui concerne le scénario des 50 ans, de la même manière qu'à 10 ans et 20 ans, les classes constructions et sols nus étaient les plus touchées par les inondations selon le modèle simulé avec, respectivement, 21,38 ha et 17,35 ha, de surfaces inondées, représentent 30,4 % et 24,6 % de la superficie totale affectée par les inondations. Pour le dernier scénario (100 ans), plus de 23,79 ha et 18,72 ha de constructions et sols nus, étaient inondés, soient 31,1 % et 24,5 % de la superficie totale inondée. Ces résultats montrent que plus la période de retour est longue, plus la plaine est vulnérable aux inondations et par conséquent les zones inondées sont grandes en termes de superficie.




Figure V. 25. Classes d'occupation du sol inondées (MNT 12 m).

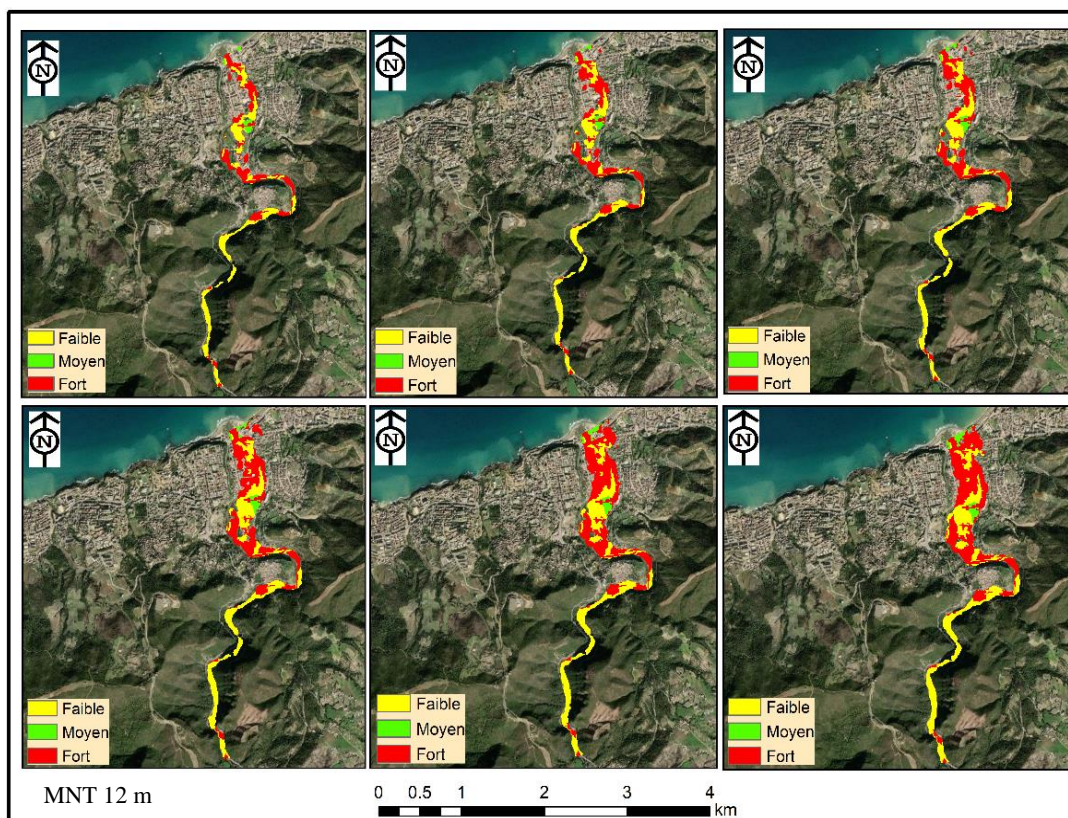


Figure V. 26. Classes d'occupation du sol inondées (MNT 12 m).

Tableau V. 11. Zones inondées prédites (MNT 12 m) pour les différents types d'occupation du sol dans la zone affectée.

Classes	Classes d'occupation du sol inondées (ha)					
	2 (ans)	5 (ans)	10 (ans)	20 (ans)	50 (ans)	100 (ans)
Eau	0,15	0,16	0,20	0,22	0,25	0,29
Forêt	2,11	2,72	3,17	3,69	3,88	3,98
Routes	9,05	10,95	12,42	14,20	15,56	16,58
Constructions	6,06	9,69	11,73	16,20	21,38	23,79
Végétation moyenne	5,98	7,01	7,62	8,17	9,21	9,98
Sols nus	11,02	13,29	14,60	15,69	17,35	18,72
Terres agricoles	0,29	0,53	0,69	0,95	1,21	1,47
Terres non agricoles	1,05	1,21	1,38	1,49	1,56	1,59
Total	35,71	45,56	51,81	60,61	70,40	76,40

Par ailleurs, le tableaux V.10 et V.12 exposent (pour les modèles MNS tri-stéréo et MNT (12 m)) les classes d'occupation du sol affectées par les inondations réparties sur les différentes classes du risque d'inondation, du moyen-faible au fort-très fort, selon le critère (Smith et al, 2014) pour les différents scénarios de récurrence des inondations.

Pour le risque simulé par le MNS tri-stéréo, Pour toutes les périodes de retour prédites, la majorité des surfaces inondées appartiennent à la classe de risque fort- très fort ($>1 \text{ m}^2/\text{s}$) avec plus de 22,28 ha, 28,76 ha, 35,36 ha, 40,28 ha, 45,92 ha et 50,9 ha équivalent à 73,5 % 77,54 % 84,91 %, 89,82 %, 90,6 % et 94,1 % pour respectivement les périodes de retour 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans. Pour 2 ans, parmi les superficies inondées à risque fort et très fort, plus de 27,7 % sont des routes et 35,2 % de sols nus inondés. Plus de 20 % des zones sujettes aux inondations sont classées dans la zone du risque moyen ($0.6 - 1 \text{ m}^2/\text{s}$) ou il y a un danger sur les véhicules et les personnes. Dans cette zone, la classe routes est la classe la plus sensible aux inondations (avec plus de 40 %). Pour la période de retour 5 ans, plus de 31.95 %, et 32.45 % de la superficie totale inondée à risque fort et très fort de la surface totale représentent

respectivement les routes et les sols nus. Plus de 17 % correspondent à la classe (0,6 – 1 m²/s) ou 66 % des routes et constructions sont faces aux inondations. En ce qui concerne la période de retour de 10 ans, plus de 71,5 % (>1 m²/s) et 15,6 % (0,6 – 1 m²/s) où les routes et les constructions sont les plus vulnérables aux inondations avec plus de 49 % de la superficie totale. Pour la période de retour 20 ans, plus de 89,82 % pour la classe (>1 m²/s) et 12 % pour la classe (0,6 – 1 m²/s) avec plus de 48 % et 65,6 %, respectivement, des routes et constructions inondées. Concernant le scénario de 50 ans de récurrence d'inondations, plus de 90,6 % des zones inondées prédites appartiennent à la zone à risque fort et très fort (>1 m²/s) et 8,96 % à risque moyen. Pour les deux classes du risque, les routes et les constructions sont considérées comme les classes les plus touchées par les inondations, avec plus de 51 % et 56 % de la surface totale inondée, pour les classes (>1 m²/s) et (0,6 – 1 m²/s), respectivement. En considérant le dernier scénario (100 ans), plus de 94,1 % des zones inondées sont à une exposition élevée-très élevée (>1 m²/s) au risque, ou 57,01% concernent les routes et les constructions. Pour la classe à risque moyen (0,6 – 1 m²/s), 4,65 % des zones inondées sont prédites avec un pourcentage très élevé des routes et des constructions inondés (plus de 53,57 %).

En outre, concernant les classes prédites de l'aléa inondation (MNT 12 m), pour le premier scénario (2 ans), plus de 78,1 % (27,89 ha) des zones touchées appartiennent à la classe du risque fort- très fort (>1 m²/s). Parmi celles-ci, environ, 26,90 % concernent les routes, 15,45 % concernent les infrastructures et les constructions et environ 31,4 % de sols nus exposés à un risque élevé-très élevé d'inondations. Plus de 11 % des zones sujettes aux inondations sont classées dans la zone du risque moyen (0,6 – 1 m²/s) où il y a un danger sur les véhicules et les personnes. Dans cette zone, la classe routes est la classe la plus sensible aux inondations (avec plus de 25 %). Pour la période de retour 5 ans, plus de 71,8 % (>1 m²/s), ou 26,5 %, 16,1 % et 31,2 % de la surface totale représentent respectivement les routes, les constructions et sols nus inondés. Plus de 21,3 % correspond à la classe (0,6 – 1 m²/s) ou 12,30% des routes et constructions sont faces aux inondations. En ce qui concerne la période de retour de 10 ans, plus de 71,5 % (>1 m²/s) et 15,6 % (0,6 – 1 m²/s) des routes et des constructions sont les plus vulnérables aux inondations avec plus de 49 % de la superficie totale. Pour la période de retour de 20 ans, plus de 65,74 % pour la classe (>1 m²/s) et 23,4 % pour la classe (0,6 – 1 m²/s) avec plus de 41,6 % et 58 %, respectivement, des routes et des constructions inondées. Concernant le scénario de 50 ans de récurrence d'inondation, plus de 65,6 % des zones inondées prédites appartiennent à la zone à risque fort et très fort (>1 m²/s) et 25,6 % à risque moyen. Pour les deux classes du risque, les routes et les constructions sont considérées comme les classes les

plus touchées par les inondations, avec plus de 42,1 % et 68,7 % de la surface totale inondée, pour les classes ($>1 \text{ m}^2/\text{s}$) et ($0,6 - 1 \text{ m}^2/\text{s}$), respectivement. En considérant le dernier scénario (100 ans), plus de 69,22 % des zones inondées sont à une exposition élevée-très élevée ($>1 \text{ m}^2/\text{s}$) au risque, ou 43,09 % concernent les routes et les constructions et 29,77 % de sols nus inondés. Pour la classe à risque moyen ($0,6 - 1 \text{ m}^2/\text{s}$), plus de 25,24 % des zones inondées sont prédites avec un pourcentage très élevé des routes et des constructions inondées (plus de 74 %).

En résumé, en tenant compte du critère utilisé pour la classification du risque d'inondation selon la quantité profondeur x vitesse d'écoulement, la classe à haut et très haut risque a le pourcentage plus élevé avec plus de 65 % des zones inondées prédites par le MNT de 12 m et plus de 73 % par le MNS tri-stéréo pour toutes les périodes de retour. Les classes routes et constructions (comprennent les infrastructures, bâtiments, maisons individuelles et espaces commerciaux) représentent les zones les plus affectées par les inondations dans la majorité des scénarios proposés. Ce résultat montre que sur le plan réel, la plaine nord du bassin versant de l'Oued Allala (région nord de la ville de Ténès) est fortement sensible au risque d'inondation à très fort degré, ou il y a un réel danger pour les véhicules et les personnes. Ainsi, les bâtiments sont vulnérables aux dommages structurels et considérés comme vulnérables aux défaillances.

Tableau V. 12. Évaluation du risque d'inondation en fonction des superficies des différents catégories d'occupation du sol (Smith et al, 2014) (MNT 12 m).

Classes du risque		Classes d'occupation du sol inondées (ha)									Total
		Eau	Forêts	Routes	Constructions	Végétation moyenne	Sols nus	Terres agricoles	Terres non agricoles	Total/ classe du risque	
2 ans	< 0,6	0,00	0,30	0,56	0,96	0,09	1,26	0,03	0,51	3,71	35,71
	0,6 - 1	0,00	0,05	0,99	0,81	0,77	1,00	0,13	0,36	4,11	
	>1	0,15	1,78	7,50	4,31	5,00	8,77	0,18	0,20	27,89	
5 ans	< 0,6	0,00	0,33	0,71	1,30	0,10	0,60	0,03	0,03	3,10	45,56
	0,6 - 1	0,00	0,35	2,05	1,97	0,75	2,85	1,11	0,66	9,74	
	>1	0,15	1,93	8,75	5,30	5,60	10,23	0,35	0,41	32,72	
10 ans	< 0,6	0,02	0,3	1,06	2,9	0,17	1,5	0,5	0,2	6,65	51,81
	0,6 - 1	0	0,72	1,38	2,6	0,53	1,91	0,4	0,55	8,09	
	>1	0,2	2,3	9,5	6	6,39	11,3	0,68	0,7	37,07	
20 ans	< 0,6	0	0,41	1,17	4	0,22	0,52	0,2	0,04	6,56	60,61
	0,6 - 1	0,05	1	2,25	6	0,6	3,1	0,2	1	14,2	
	>1	0,2	2,45	10,21	6,4	7,74	11,6	0,55	0,7	39,85	
50 ans	< 0,6	0	0,1	0,4	4,25	0,23	1,02	0,12	0	6,12	70,4
	0,6 - 1	0,01	1,1	3,4	9,01	0,69	3	0,4	0,45	18,06	
	>1	0,21	3,1	11,33	8,2	8,03	13,6	0,64	1,11	46,22	
100 ans	< 0,6	0	0,1	0,59	2,31	0,09	0,99	0,12	0,02	4,22	76,4
	0,6 - 1	0,01	0,82	2,7	11,97	0,73	2,49	0,45	0,12	19,29	
	>1	0,27	3,3	12,87	9,92	8,52	15,75	0,8	1,46	52,89	

V.3.3.4. Analyse du risque global

Les figures V.27 et V.28 représentent les cartes du risque global obtenues par les modèles MNS tri-stéréo et MNT (12 m). Ainsi, les tableaux V.13 et V.14 montrent les superficies totales pour chaque classe du risque.

Le tableau V.13 reporte la répartition du risque globale d'inondation généré à partir du modèle Tri-stéréo en matière de superficies en hectare (ha). En effet, le risque augmente avec l'augmentation de la période de retour. Pour les deux premières périodes de retour (2, et 5 ans)

le degré du risque était de moyen à fort. En termes de superficie, la plupart des zones à risque appartiennent à la classe de risque moyen avec plus de 16.36 et 18.40 ha.

Par ailleurs, le risque devient plus fort pour les périodes de retour (10 ,20,50 et 100 ans), où la classe du risque fort est la plus dominante en terme de superficie avec respectivement plus de 21.51, 23.52, 26.89 et 28.73 ha.

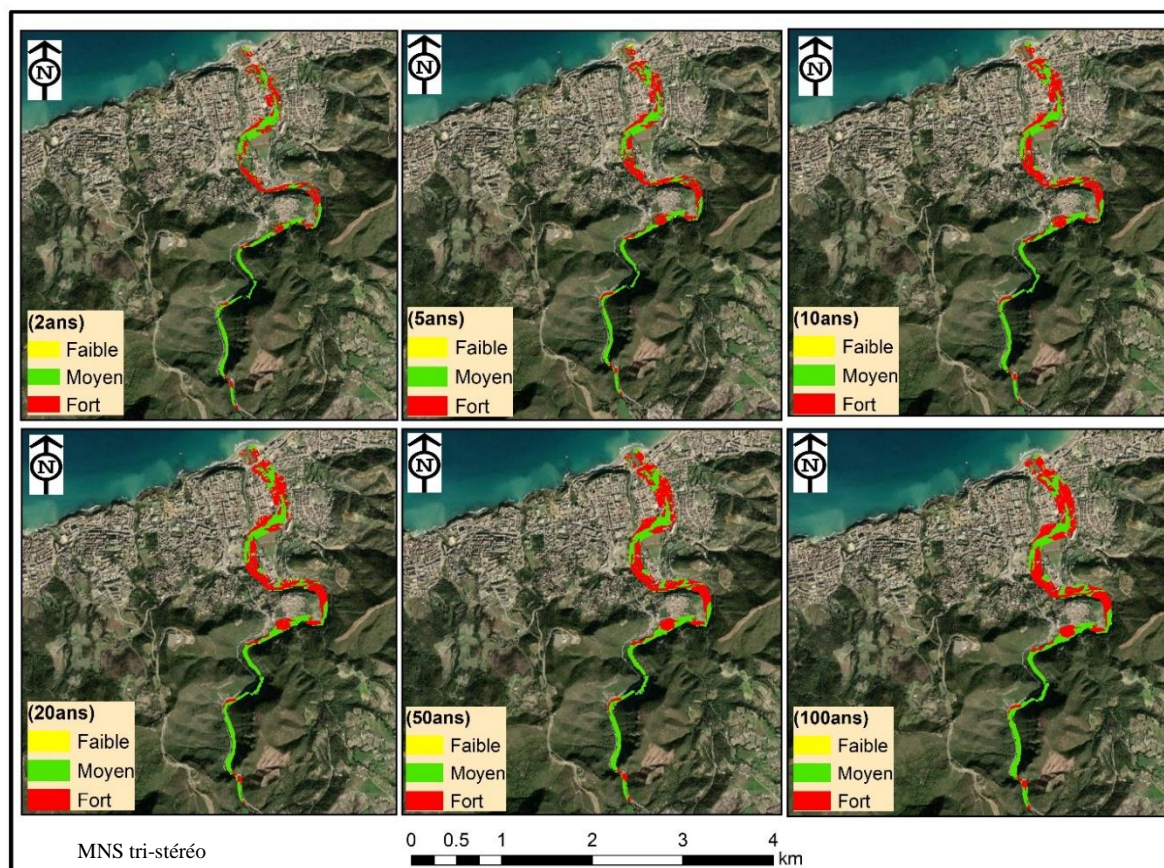


Figure V. 27. Carte du risque global d'inondation (MNS tri-stéréo) pour les différentes périodes de retours étudiées.

Tableau V. 13. Superficies des classes du risque global (MNS tri-stéréo).

Risque	Superficie (ha)					
	2 ans	5 ans	10 ans	20 ans	50 ans	100 ans
Faible	0,44	0,53	0,35	0,16	0,3	0,26
Moyen	16,36	18,40	19,79	21,74	23,46	25,1
Fort	13,51	18,16	21,51	23,52	26,89	28,73
Total	30,31	37,09	41,65	45,42	50,65	54,09




Figure V.28. Carte du risque global d'inondation (MNT 12 m) pour les différentes périodes de retours étudiées.

Tableau V.14. Superficies des classes du risque globale (MNT 12 m).

Risque	Superficie (ha)					
	2 ans	5 ans	10 ans	20 ans	50 ans	100 ans
Faible	2	2,5	1,5	1,4	1,09	2,4
Moyen	19,7	24	28	32,2	34,51	35
Fort	14	19	22,3	27	34,8	39
Total	35,7	45,5	51,8	60,6	70,4	76,4

Par ailleurs, le tableau V.14 illustrant la répartition du risque global d'inondation généré à partir de modèle MNT (12 m) en termes de superficies, la tendance d'évaluation du risque augmente avec l'augmentation de la période de retour. Pour les premières périodes de retour (2, 5, 10 et 20 ans) le degré du risque était plus ou moins moyen à fort. Pour les périodes (50 et 100 ans), en terme de superficie, la plupart des zones à risque appartiennent à la classe de risque fort avec plus de 34,8 ha pour 50 ans et de 39 ha pour la période de retour 100 ans.

Dans l'ensemble, pour les deux modèles de simulation, en tenant compte des dernières périodes de retour, le risque d'inondation apparaît fréquemment dans la région du Vieux-Ténès proche

de la côte, où les infrastructures sont en face d'un risque réel. Le risque global s'avère relativement haut pour les périodes 50 et 100 ans, notamment sur la rive droite (de l'amont à l'aval) du cours d'eau Oued Allala. Sur le plan opérationnel l'aménagement du cours d'eau Allala doit être renforcé selon les résultats de la période de retour centennale.

V.4. Discussion générale

Dans ce chapitre, une analyse du risque d'inondation en matière d'aléa et vulnérabilité a été effectuée sur le bassin versant de l'Oued Allala. Les simulations des scénarios d'inondation sur six périodes de retour ont été réalisées à l'aide du logiciel HEC-RAS. Les prédictions d'aléa ont été créées avec deux modèles topographiques d'élévation, à savoir le MNS tri-stéréo provenant d'un image Pléiade tri-stéréo et le MNT provenant du satellite ALOS. Ces modèles topographiques sont évidemment différents en termes de résolution spatiale et de caractéristiques spatiales de surface terrestre, l'objectif principal de leur utilisation étant d'évaluer leurs contributions dans la simulation des inondations et la caractérisation des zones vulnérables au risque d'inondation.

Sur le plan comparatif entre les deux modèles simulateurs, en matière de profondeur d'eau, vitesse d'écoulement et les superficies inondées, le modèle (MNT 12 m) a permis de prédire des scénarios d'inondations plus graves en comparaison avec celui de tri-stéréo. Des différences remarquables également ont été constaté pour ce qui superficies inondées pour toutes les périodes de retour prédites. D'ailleurs, le MNT (12 m) a surpassé le MNS tri-stéréo avec plus de 5,4 ha, 8,47 ha, 10,16 ha, 15,19 ha, 19,75 et 22,31 ha pour 2 ans, 5 ans, 10 ans, 20 ans, 50 ans et 100 ans, respectivement de surfaces inondées. Ces résultats expliquent que le risque prédit pour le MNT (12 m) est plus fort que celui de MNS tri-stéréo. Cette surestimation implique ainsi une surestimation des dommages causés par le risque et notamment en ce qui concerne le zonage de l'occupation du sol exposé au risque d'inondation. En outre, sur le plan économique, si la gestion des inondations dans la zone affectée prend en considération les résultats fournis par le MNT (12 m), cela signifie que même le cout des projets d'aménagement et de planification des zones inondables sera plus grand. Néanmoins, le risque d'aléa prédit est raisonnable et les résultats de simulation sont relativement conformes avec ceux obtenus par d'autres application dans la même zone d'étude. Par exemple, (Kastali et al., 2021) ont évalué le risque d'inondation dans la zone du Vieux-Ténès sous l'effet de l'incertitude des courbes de tarage. Ils ont utilisé un modèle topographique prélevé sur terrain et les simulations sont effectuées pour la crue centennale à l'aide de logiciel HEC-RAS également. En considérant le débit centennal utilisé pour la simulation ($1010 \text{ m}^3/\text{s}$) le plus proche au débit utilisé dans notre

cas, les surfaces globales inondées étaient de 58,30 ha. En comparaison avec les résultats de notre étude (54,09 ha) simulé par MNS pour la crue centennale, nous constatons une légère différence de 4 ha. Ainsi, ce modèle s'avère raisonnable et plus fiable et estime réellement les zones inondées. Un aperçu des résultats d'analyse du risque aléa et du risque global simulés par la crue centennale sont montrées dans les figures V.29 et V.30.

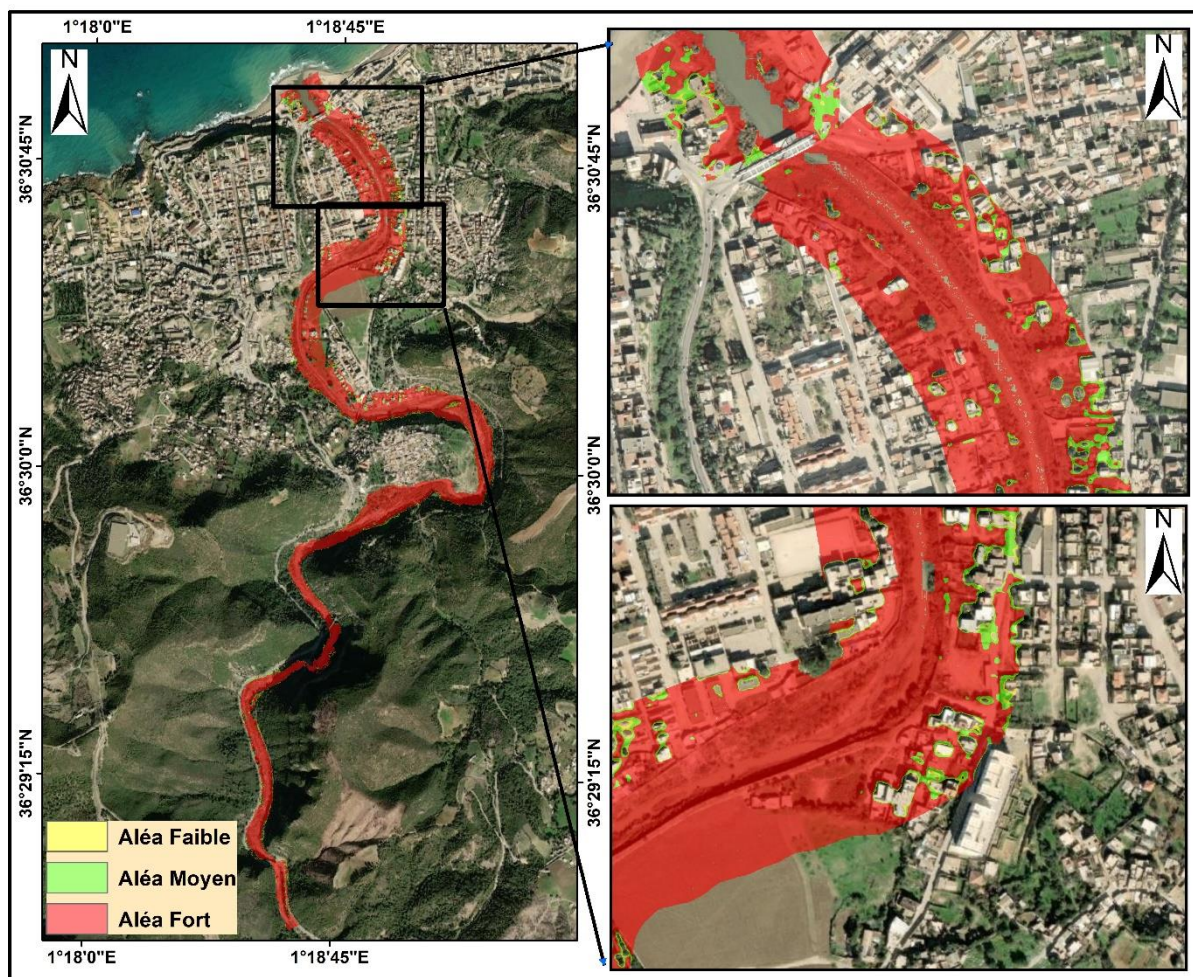


Figure V.29. Zoom sur le risque aléa simulé par la crue centennale (MNS tri-stéréo).

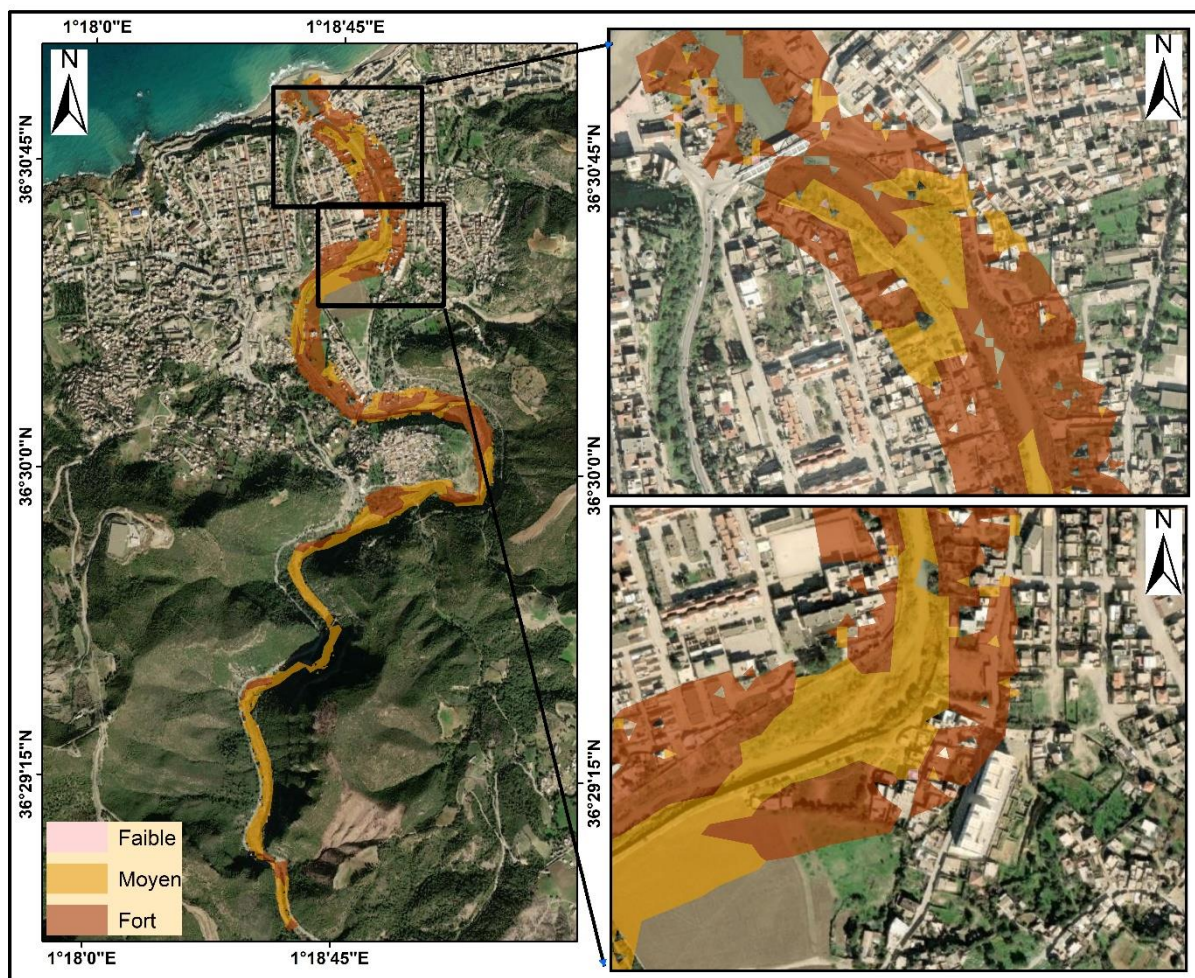


Figure V.30. Zoom sur le risque global d'inondation simulé par la crue centennale (MNS tri-stéréo).

Par ailleurs, pour mieux valider nos résultats d'analyse du risque d'inondation, notamment en matière de caractérisation spatiale et de vulnérabilité au risque, nous avons appliqué une autre approche méthodologique pour la comparaison. Cette approche consiste principalement en cartographie du risque d'inondation selon l'approche FIGUSED-S développée par (Kazakis, Kougias, Patsialis 2015), destinée particulièrement à la cartographie régionale du risque d'inondation en fonction des indicateurs hydro-morphologiques et topographiques. L'objectif est de comparer les résultats de la répartition spatiale du risque d'inondation par cette méthode avec nos résultats. La méthode a été appliquée à l'échelle de tout le bassin versant de l'Oued Allala. Les principaux paramètres utilisés pour la cartographie spatiale sont : l'occupation du sol, les altitudes, les précipitations, la densité de drainage et les pentes. L'idée est de reclasser les classes de chaque paramètre spatial en fonction du degré de risque et par priorité de paramètre. Pour le paramètre occupation du sol, deux cartes correspondantes aux années 2020 et 2009 ont été utilisées (résultats de chapitre VI), pour évaluer l'impact de l'évaluation de

l'occupation du sol sur le risque d'inondation. Les cartes caractéristiques de chaque paramètre spatial sont montrées dans les figures (V.31- V.36).

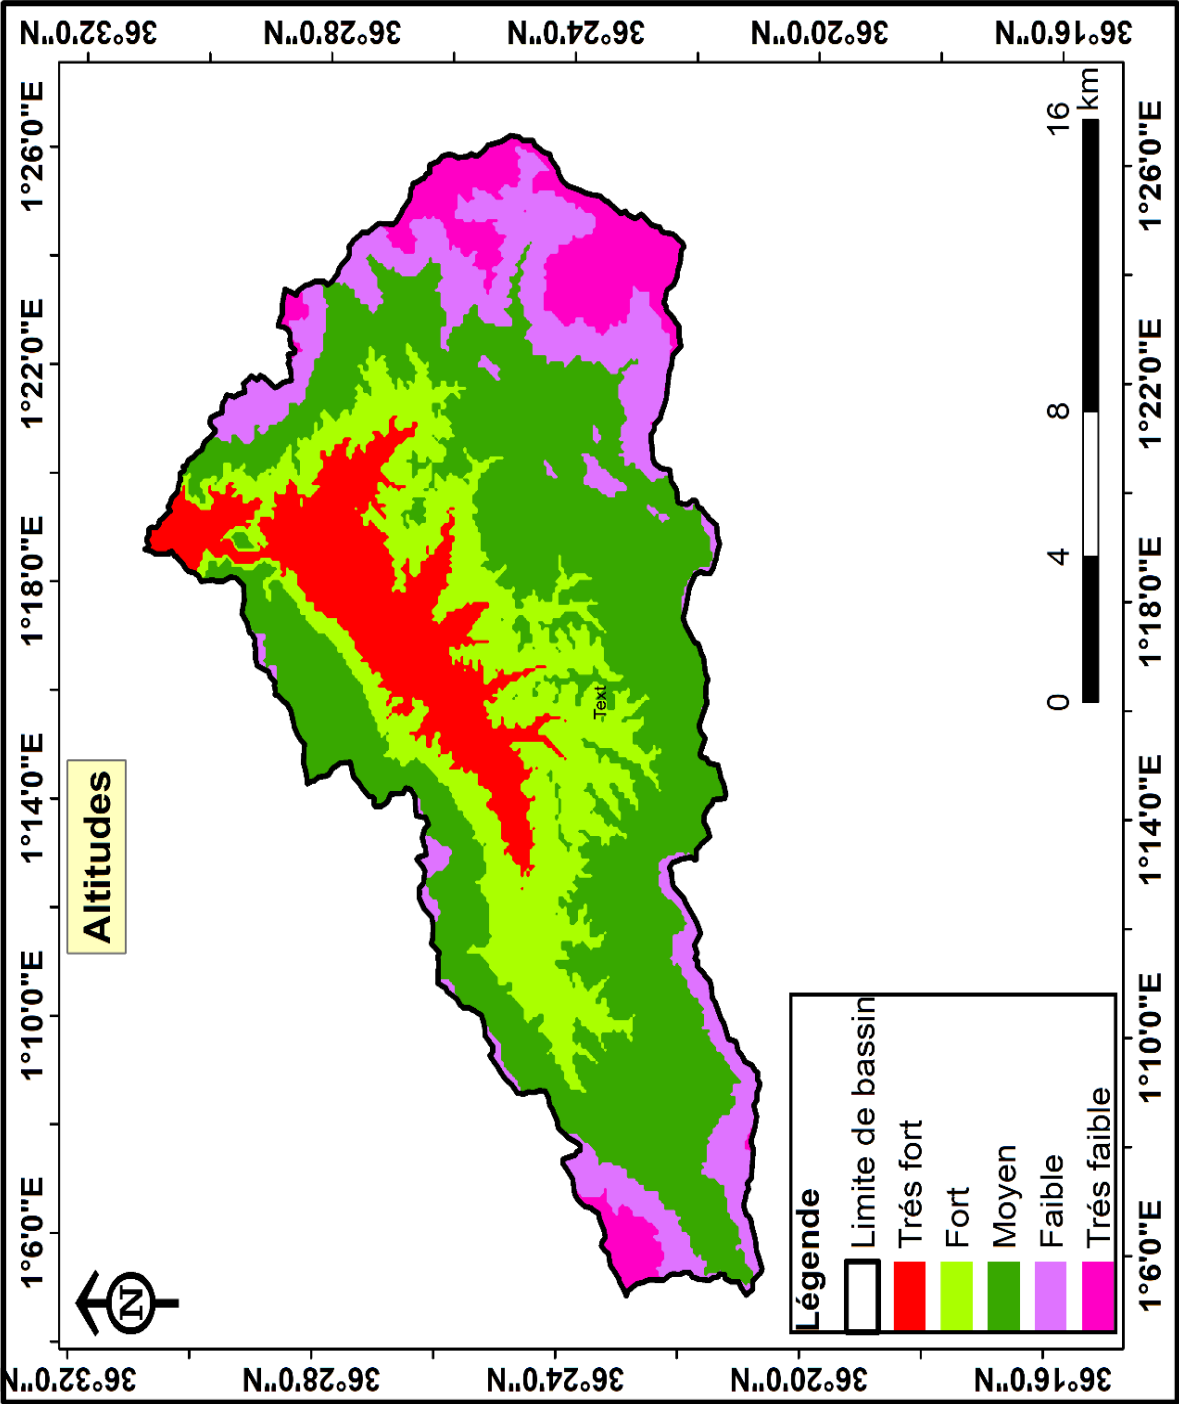


Figure V.31. Indice d'élévation de bassin versant Oued Allala.




Figure V. 32. Indice de l'intensité des précipitations du bassin versant Oued Allala.




Figure V.33. Indice de densité de drainage.




Figure V. 34. Indice de pentes de bassin versant Oued Allala.

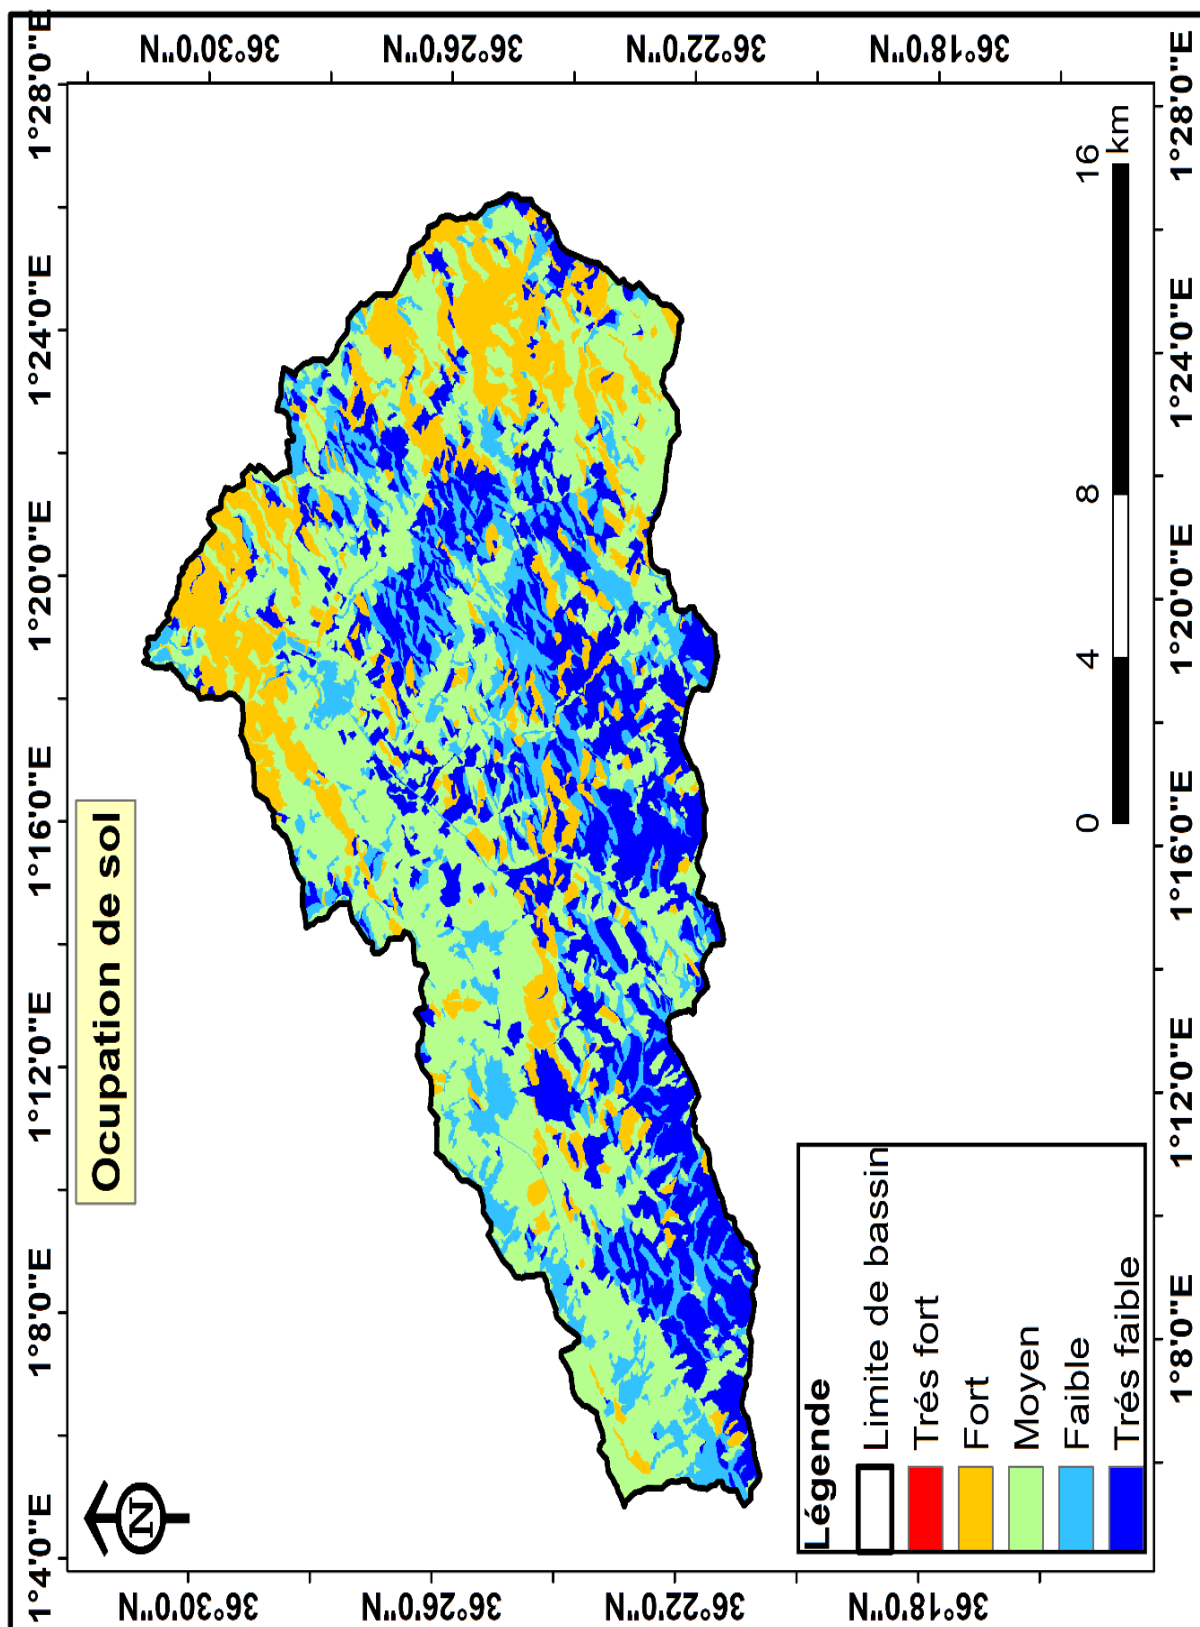


Figure V. 35. Indice d'occupation du sol (année- 2020).




Figure V. 36. Indice d'occupation du sol (année- 2009).

▪ **Analyse du risque global :**

Les cartes V.37 et V.38 exposent les résultats de la cartographie spatiale du risque d'inondation pour l'année 2020 et l'année 2009, tiennent compte de l'évolution de l'occupation du sol au cours des 11 ans étudiés. Cinq classes de risque ont été identifiées de très faible à très fort.

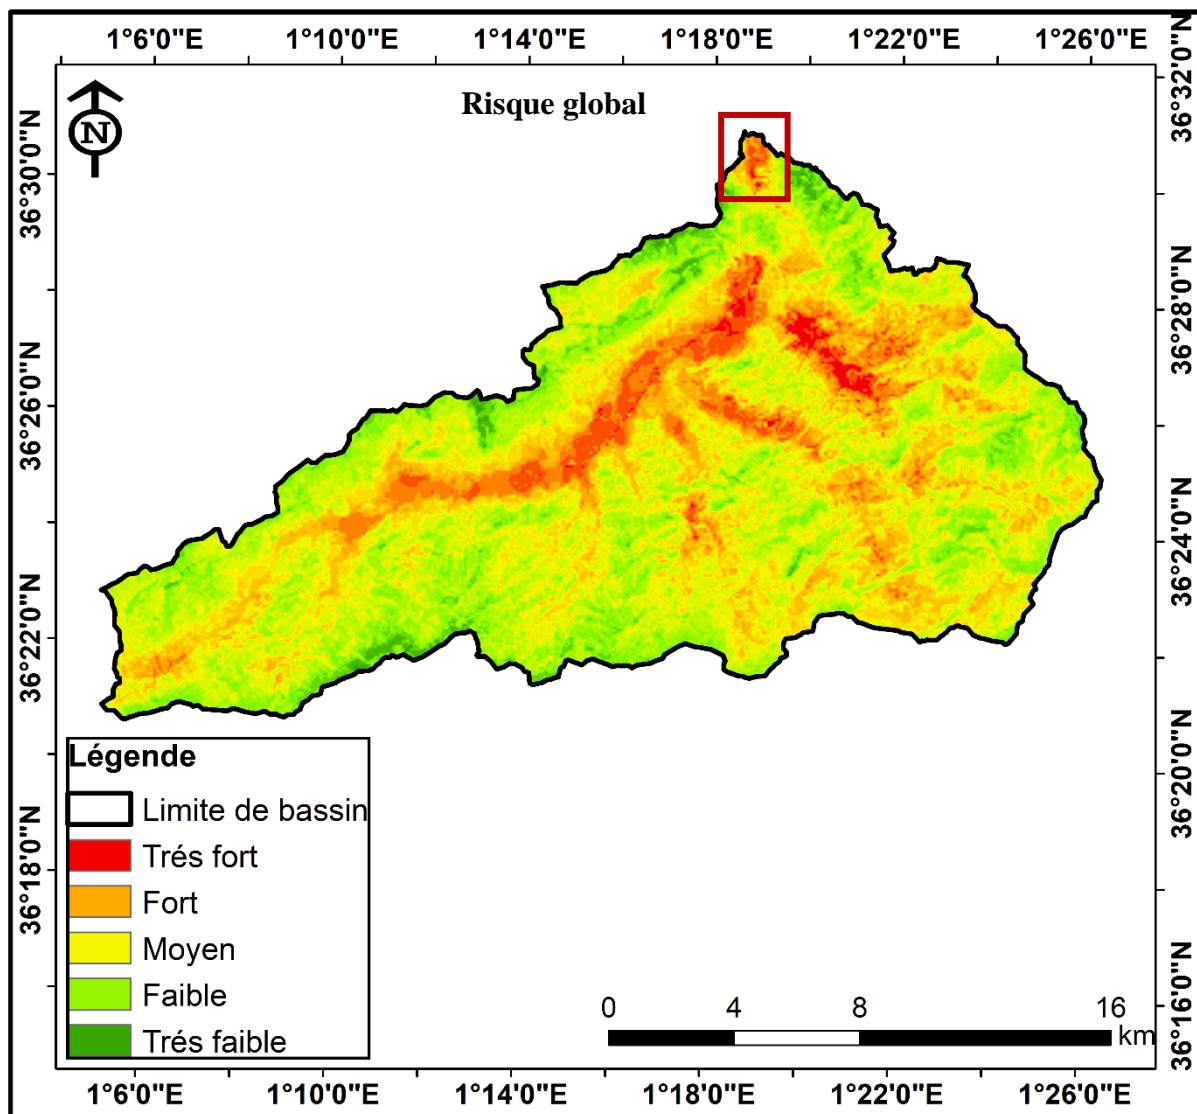


Figure V.37. Indice spatial de la caractérisation du risque d'inondation selon la méthodologie FIGUESD-S – Année 2020.

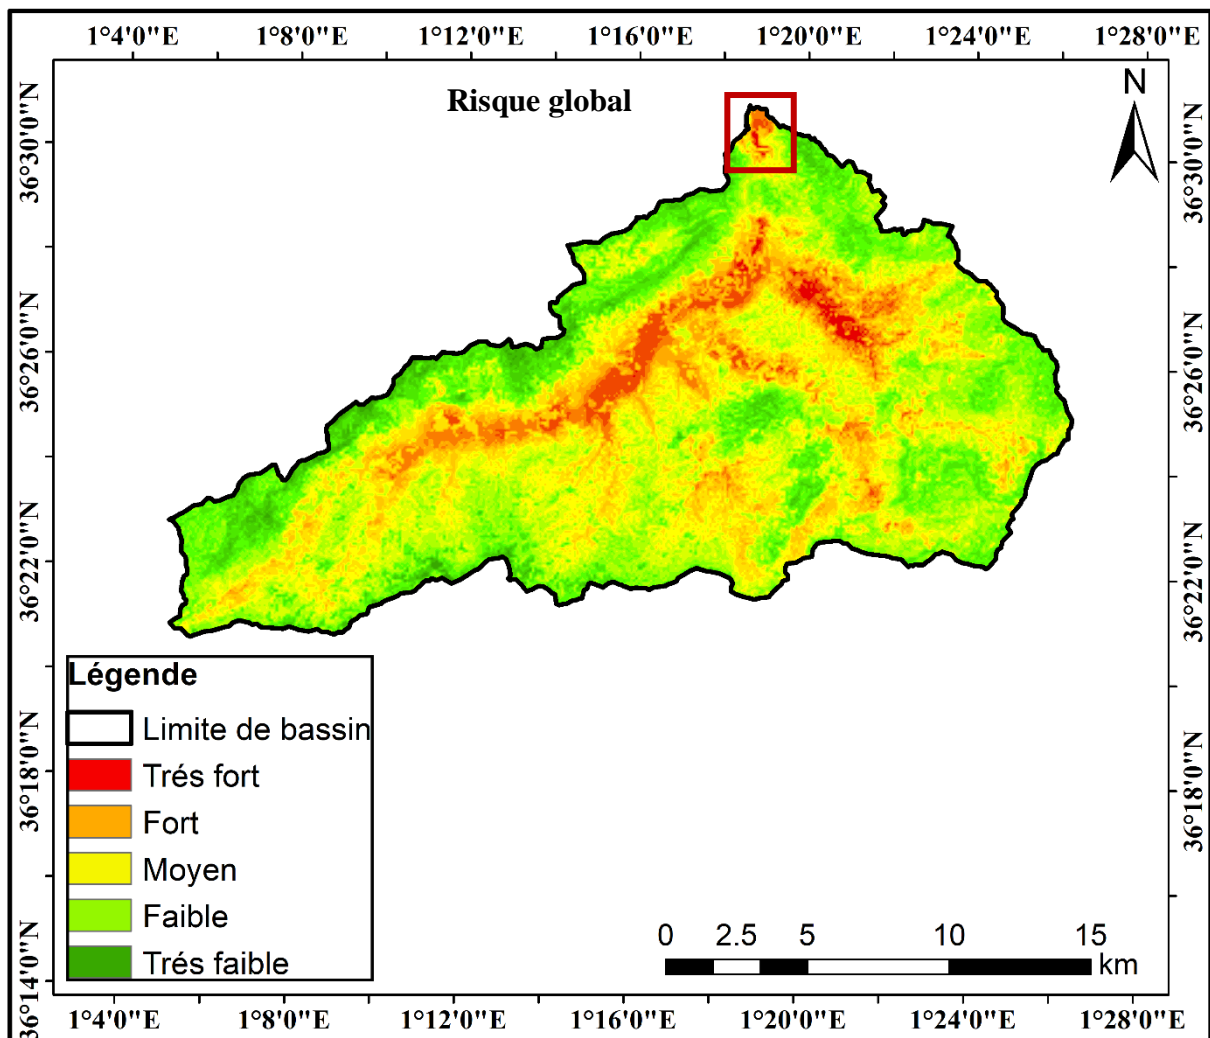


Figure V. 38. Indice spatial de la caractérisation du risque d'inondation selon la méthodologie FIGUESD-S – Année 2009.

Les résultats montrent que pour les deux années d'étude, le risque d'inondation est plus fort à proximité du cours d'eau Oued Allala et ses rives gauches et droites. En outre, l'analyse visuelle des cartes produites montre que la zone étudiée pour le cas de simulation hydraulique qui considère le tronçon nord proche de la mer est également sujette à un risque fort (zone orange) et très fort (Zone rouge). Par ailleurs, il y a une différence entre les deux cartes en matière de zonage de chaque classe de risque. Cela est mieux expliqué par le calcul des surfaces. Le tableau V.15 expose les surfaces vulnérables au risque d'inondation pour les années 2020 et 2009.

Tableau V.15. Répartition des surfaces à risque d'inondation selon les classes du risque global.

Classe de risque	Zones exposées au risque (ha)	
	2009	2020
Très faible	4285	3240
Faible	10888	13582
Moyen	12492	10538
Fort	2640	2817
Très fort	309	437

D'après le tableau des répartitions des superficies à risque d'inondation, les superficies sont considérablement différentes de classe de risque très faible à très fort. En comparant les deux années, nous constatons que la classes très faible et moyen ont diminué de l'année 2009 à 2020. Ce qui engendre une augmentation de superficies des autres classes à savoir faible, fort et très fort. Par conséquent, vu que les autres indices spatiaux sont les mêmes utilisés pour les deux scénarios du risque (2009 et 2020), donc risque augmente avec l'évolution de l'occupation du sol, et la zone nord devient plus vulnérables.

Ces résultats confirment l'impact de l'évolution de l'occupation du sol dans le temps sur l'évolution du risque spatial. Cela a été également démontré dans nombreuses études (Zope et al., 2016 ; Sugianto et al., 2022).

Bien que les données satellitaires à très haute résolution spatiale utilisées dans cette étude contribuent de manière significative à l'efficacité de telles études, elles créent des données volumineuses qui peuvent nécessiter un traitement très exigeant, révélant des défis et des opportunités pour plusieurs aspects des systèmes de gestion du risque d'inondation. En même temps la qualité des informations détaillées de la classification de l'occupation du sol a contribué parfaitement à l'étude des inondations dans les deux aspects : modélisation de l'aléa et vulnérabilité des plaines exposées aux inondations.

Les données Pléiades avec le potentiel d'observation de la surface terrestre ainsi que la capacité tri- stéréoscopique offrent la possibilité d'une cartographie complète du risque d'inondation. Les données topographiques ainsi produites à partir des données Pléiades ont contribué à une simulation relativement réelle des inondations en tenant compte tous les obstacles d'écoulement notamment en milieu urbain, cela a permis de générer des écoulements qui rapprochent de la

réalité. Ainsi la comparaison de ces résultats avec d'autres études dans la même région a montré la fiabilité de l'approche utilisée notamment les résultats obtenus par les données Pléiades tri-stéréo.

Par ailleurs, par l'application d'une approche comparative basée sur l'évaluation du risque global d'inondation à travers des indicateurs topographiques et hydrauliques tels que l'intensité de la pluie, la densité de drainage, la pente, l'altitude et l'occupation du sol.

Les résultats de cette approche basée sur les données cartographiques de précision ont montré indéniablement que la zone étudiée, en l'occurrence la cité de l'ancienne ville côtière de Ténès est fortement exposée au risque d'inondation. Le risque d'inondation est globalement variable de fort à très fort.

Une situation qui mérite la mise en place urgente d'une étude d'élaboration d'un Plan de Prévention au Risque d'Inondation (PPRI), qui doit être conjugué à un dispositif d'alerte au niveau des points et sections névralgiques de l'écoulement.

**CONCLUSION
GÉNÉRALE ET
PERSPECTIVES**

CONCLUSION GÉNÉRALE ET PERSPECTIVES

La prévention aux risques d'inondation demeure un atout capital dans la mise en place d'une stratégie nationale de lutte contre les risques majeurs par l'identification des zones inondables à risque, notamment dans les villes côtières à urbanisation galopante, non planifiée et même parfois informelle. Cette dernière qui risque de prendre de l'ampleur avec le changement climatique, en raison du flux migratoire des populations des pays du sahel vers le nord du pays.

Afin d'y parvenir, une stratégie établie à l'horizon 2030 visant à la prévention et la gestion des risques d'inondation favorisant des actions non structurelles de prévention. À ce titre, des études topographiques, hydrologiques et des simulations via la modélisation hydraulique s'imposent visant à l'élaboration des cartes du risque d'inondation, le zonage et la planification de l'occupation du sol dans telles zones ainsi l'implémentation des plans de prévention du risque d'inondations (PPRI) sont souvent les points notables les plus abordés à l'issue de ces stratégies.

Tenant compte de la particularité des zones côtières à l'Ouest algérien qui sont fréquemment exposées à un risque fort d'inondations et dans l'impact économique et social est toujours saillant. Afin de réduire la vulnérabilité des villes côtières, un plan d'action multisectoriel est défini accompagné d'un suivi afin de maintenir un niveau optimum de connaissance par des actions proactives.

C'est dans ce cadre que la présente thèse a été mise en place pour répondre à cette véritable problématique ayant comme objectif principal l'évaluation de l'apport des nouvelles données satellitaires pour l'étude et l'analyse du risque d'inondation des zones côtières inondables.

Afin de répondre à la question d'une meilleure appréhension de la vulnérabilité à l'inondation en zones côtières, une approche détaillée est proposée, basée sur la modélisation de l'occupation du sol à partir des données et méthodes de télédétection dans des régions côtières exposées au risque d'inondation.

La démarche présentée a permis d'évaluer et de cartographier l'occupation du sol des zones côtières d'Ain Témouchent et de Ténès, située dans l'ouest de l'Algérie. Un modèle d'apprentissage profond (*Deep Learning*) CNN (*Convolutional Neural Networks*) combiné avec la méthode OBIA (*Object-Based Image Analysis*) a été appliqué, et des méthodes d'apprentissage

automatique (*Machine Learning*) basées sur des classificateurs RF (*Random Forest*) et SVM (*Support Vector Machine*) ont été testées.

Les méthodes appliquées ont été menées sur différents types de données de télédétection à différentes caractéristiques et résolution spatiales, telles que Pléiades, Sentinel-2, Sentinel-1 et Landsat-5 TM. L'objectif était de tester la contribution et le potentiel de chacune des données spatiales pour l'extraction des caractéristiques de l'occupation du sol. En outre, des démarches méthodologiques ont été appliquées notamment la fusion optique radar et l'évaluation des changements de l'occupation du sol.

En ce qui concerne l'approche synergique des données optiques et radars pour la classification de l'occupation du sol, l'idée était de contribuer à l'amélioration de la précision des cartes de l'occupation du sol à travers la combinaison des caractéristiques spatiales et spectrales de Sentinel-1 et Sentinel-2. En tenant compte de l'effet de la résolution spatiale, cette approche a mis en valeur la précision de l'extraction des classes d'occupation du sol appartenant à un niveau détaillé avec une nomenclature adaptée au risque d'inondation. Cependant, l'effet de la résolution spatiale des données utilisées (Sentinel-1 et Sentinel-2) nous a guidé à tester d'autres données spatiales à très haute résolution spatiale (THRS) et d'autres méthodes de classification, afin de mieux reconnaître les éléments présents dans une zone inondable, autrement dit, les « enjeux à risque d'inondation »

Dans la même optique, à l'issue de l'application de la nouvelle méthode proposée dans cette thèse qui intègre les CNNs et l'approche OBIA, le niveau d'extraction de l'information a été réellement améliorée grâce au potentiel des CNNs et de leur architecture permettant une extraction de haut niveau des caractéristiques spatiales. En effet, les paramètres de l'architecture CNN, en particulier la taille des patchs d'échantillon et des couches CNN (y compris les couches cachées, de convolution et de mise en commun maximale) ont été optimisées pour produire une architecture de modèle optimale et améliorer la précision finale de la classification. Le modèle CNN profond proposé, intégré à OBIA a montré des améliorations significatives dans la cartographie de l'occupation du sol par rapport à d'autres classificateurs d'apprentissage automatique, atteignant une précision globale (OA) et un kappa de 93,5 % et 0,91 pour les données Pléiades, et 83,4 % et 0,80 pour les données Sentinel-2. En revanche, malgré la capacité des modèles CNN dans l'extraction à haut niveau, leur intégration avec la méthode OBIA a amélioré encore plus l'extraction de l'information, en particulier, à travers l'optimisation des paramètres de segmentation, et notamment le paramètre d'échelle dans la segmentation Multi-resolution qui est essentielle pour contrôler la taille des objets.

Les résultats des méthodes d'apprentissage automatique ont confirmé que l'OBIA surpassait l'analyse basée sur les pixels, et que la RF était plus stable que le SVM pour toutes les données spatiales utilisées. En outre, étant donné l'effet de la résolution spatiale, les résultats obtenus avec l'image Pléiades ont montré des précisions plus importantes des cartes de l'occupation du sol indépendamment des méthodes testées.

Les résultats obtenus dans ce premier volet ont révélé qu'il est possible de cartographier avec beaucoup de précisions l'occupation du sol des plaines inondables dans les zones côtières en utilisant des algorithmes d'apprentissage automatique appliqués à des données ayant des résolutions spatiales différentes. Le niveau des catégories extraites dépend de la résolution choisie et malgré la résolution des données Sentinel-2, des cartes visiblement utilisables ont été produites. Cependant, pour des analyses plus fiables qui nécessitent des détails plus précis de l'occupation du sol à une échelle fine, l'utilisation des images à très haute résolution spatiale (THRS) est recommandée, particulièrement dans les zones côtières hétérogènes. Les cartes finales produites ici peuvent servir de base de données pour l'évaluation de la vulnérabilité aux inondations, qui requière des informations finement détaillées sur les catégories de l'occupation du sol pendant le processus de modélisation. Ces cartes peuvent également être considérées comme un outil fiable pour soutenir la prise de décision au niveau régional et national concernant le zonage de l'occupation du sol des régions à risque dans les sites étudiés.

Le deuxième volet de cette thèse s'est intéressé à l'évaluation du risque d'inondation en milieu urbain à travers une approche combinée des résultats de classification de l'occupation du sol et une modélisation hydraulique pour la caractérisation de l'aléa inondation. L'objectif était d'évaluer l'apport de la télédétection en matière d'amélioration des modèles de simulation hydraulique. En complément de l'imagerie satellitaire exploitée en matière d'occupation du sol pour la modélisation hydraulique, l'approche proposée a intégré en amont du modèle hydraulique des données topographiques, issues de modèles numériques à très haute résolution spatiale. En effet, le traitement numérique de l'image Pléiades stéréoscopique a permis de générer un Modèle Numérique de Surface (MNS) utilisé pour créer la géométrie du cours d'eau étudié et de la plaine inondable. Pour mieux évaluer l'apport de ce modèle topographique, nous avons utilisé un autre Modèle Numérique de Terrain (MNT) à 12 m de résolution pour la comparaison. Le bassin versant de l'Oued Allala a été choisi comme site d'étude pour tester la démarche méthodologique proposée.

Par conséquent, en fonction de différents aspects spatiaux, topographiques et hydrologiques, des simulations hydrauliques à l'aide du modèle HEC-RAS (*Hydrologic Engineering Centers*

River Analysis System) ont été réalisées pour différentes périodes de retour. Les simulations hydrauliques ont permis de représenter l'extension des ondes de crue dans les canaux principaux d'écoulement, de délimiter les plaines inondables et de déterminer les niveaux d'eau associés aux périodes d'occurrence.

Des cartes de l'aléa ont été élaborées en fonction des profondeurs d'eau et des vitesses d'écoulement simulées par le modèle HEC-RAS. Ensuite, ces caractéristiques d'aléa ont été croisées avec l'occupation du sol des zones inondables pour la détermination de la vulnérabilité. L'analyse de la vulnérabilité consiste donc à identifier les zones d'occupation des sols sous l'influence potentielle d'une inondation de période de retour particulière. Ces résultats ont été ensuite combinés pour l'analyse du risque global d'inondation.

Les principaux résultats de cette partie ont montré que les zones susceptibles d'être inondées sont principalement situées près de la rivière, et s'étendent vers la plaine inondable du bassin versant Oued Allala. Ces zones sont caractérisées par la présence d'infrastructures et les constructions en raison de l'expansion de l'extension urbaine. Cette concentration urbaine rend ces zones très critiques et par conséquent, plus vulnérables aux inondations.

Les données satellitaires à très haute résolution spatiale utilisées dans ce travail apportent de manière significative de l'efficacité de ces applications. En effet, la précision des informations détaillées de la classification de l'occupation du sol contribue parfaitement à l'étude des inondations dans les deux aspects : modélisation de l'aléa et vulnérabilité des plaines exposées aux inondations. Ainsi les MNS acquis à partir de l'image Pléiades tri-stéréo ont offert une opportunité inédite pour une cartographie très précise du risque d'inondation. Ces modèles topographiques ont contribué à la caractérisation relativement réelle de l'aléa inondation et ont pris en considération les obstacles surfaciques de l'écoulement en milieu urbain y compris le cadre bâti et la végétation. Ainsi la comparaison des résultats obtenus par MNS avec ceux obtenus par d'autres études dans la même région a montré la fiabilité des résultats obtenus par l'approche proposée.

Enfin et pour valoriser les résultats de la caractérisation spatiale des zones vulnérables au risque d'inondation, une approche basée sur la combinaison des indicateurs hydro morphologiques et topographiques a été proposée. Les principaux paramètres utilisés pour la cartographie spatiale sont : l'occupation du sol, les altitudes, les précipitations, la densité de drainage et les pentes du terrain.

Le principe était de définir des niveaux de risque pour chaque indicateur puis ensuite de combiner l'ensemble des indicateurs classés pour définir le risque global. Les résultats obtenus par cette méthode ont confirmé que la région côtière du bassin versant de l'Oued Allala se trouve face à un risque d'inondation très élevé. Plus particulièrement, les résultats de la caractérisation spatiale ont démontré que la cité de l'ancienne ville côtière de Ténès est fortement exposée au risque d'inondation. Le risque d'inondation est variable de fort à très fort ou les infrastructures sont en face d'un risque réel. En outre, le risque global est très élevé pour les périodes de retour de 50 et 100 ans, notamment sur la rive droite (de l'amont à l'aval) du cours d'eau Oued Allala.

Cette situation mérite sur le plan opérationnel le renforcement du plan d'aménagement de l'Oued Allala selon les résultats de la période de retour centennale. Ainsi, l'élaboration d'un plan de prévention au risque d'inondation (PPRI), qui doit être conjugué à un dispositif d'alerte et d'aménagement au niveau des points et sections névralgiques de l'écoulement afin d'épargner tout danger. Ainsi, les cartes établies à partir de l'analyse de l'aléa, de la vulnérabilité et du risque global sont considérées comme outils performants qui pourront être exploitées par les décideurs et les responsables régionaux pour réduire et atténuer l'impact des inondations dans les différentes parcelles en milieu urbain situées sur le bassin versant de la zone d'étude.

L'application des approches proposées dans cette recherche à la lumière des résultats obtenus peut inaugurer à des perspectives multiples et intéressantes à savoir dans :

- L'évaluation de l'impact des changements de l'occupation du sol sur les processus hydrologiques et hydrauliques de ruissellement de surface dans un contexte hydrologique qui s'adapte à la zone côtière sujette aux crues extrêmes en Algérie.
- Intégrer d'autres indicateurs de la vulnérabilité avec l'indicateur d'aléa et d'occupation du sol afin de déterminer un indice fiable permettant une caractérisation plus fiable de la vulnérabilité.
- L'expérimentation de la méthodologie proposée à d'autres bassins versants à forte densification du sol pour des caractéristiques topographiques et hydro-morphologiques différentes afin d'évaluer le degré de fiabilité et les limites de l'approche.
- L'exploitation des possibilités de Machine et Deep Learning dans les modèles de simulation hydraulique sur la base d'algorithme intégrant la dynamique des parcelles de terrains affectées par le facteur d'occupation de sol et voir son impact sur la vulnérabilité, autrement le risque à l'inondation.

REFERENCES
BIBLIOGRAPHIQUES

REFERENCES BIBLIOGRAPHIQUES

- ABDULKAREEM, Jabir Haruna, SULAIMAN, Wan Nor Azmin, PRADHAN, Biswajeet, et al. Long-term hydrologic impact assessment of non-point source pollution measured through land use/land cover (LULC) changes in a tropical complex catchment. *Earth systems and environment*, 2018, vol. 2, no 1, p. 67-84.
- ADGER, W. Neil. Vulnerability. *Global environmental change*, 2006, vol. 16, no 3, p. 268-281.
- ADUGNA, Tesfaye, XU, Wenbo et FAN, Jinlong, 2022. Comparison of Random Forest and Support Vector Machine Classifiers for Regional Land Cover Mapping Using Coarse Resolution FY-3C Images. *Remote Sensing*. 25 janvier 2022. Vol. 14, n° 3, pp. 574. DOI 10.3390/rs14030574.
- Airbus, 2022, Pléiades Imagery User Guide. <https://www.intelligence-airbusds.com/en/8718-user-guides> .
- AKAIKE, Hirotugu. A new look at the statistical model identification. *IEEE transactions on automatic control*, 1974, vol. 19, no 6, p. 716-723.
- ALONSO, Laura, PICOS, Juan et ARMESTO, Julia, 2021. Forest Land Cover Mapping at a Regional Scale Using Multi-Temporal Sentinel-2 Imagery and RF Models. *Remote Sensing*. 8 juin 2021. Vol. 13, n° 12, pp. 2237. DOI 10.3390/rs13122237.
- ALQURASHI, Abdullah F., KUMAR, Lalit, et SINHA, Priyakant. Urban land cover change modelling using time-series satellite images: A case study of urban growth in five cities of Saudi Arabia. *Remote Sensing*, 2016, vol. 8, no 10, p. 838.
- AMINI, Saeid, HOMAYOUNI, Saeid, SAFARI, Abdolreza et DARVISHSEFAT, Ali A., 2018. Object-based classification of hyperspectral data using Random Forest algorithm. *Geo-spatial Information Science*. 3 avril 2018. Vol. 21, n° 2, pp. 127-138. DOI 10.1080/10095020.2017.1399674.
- AMITRANO, Donato, DI MARTINO, Gerardo, IODICE, Antonio, et al. Unsupervised rapid flood mapping using Sentinel-1 GRD SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, vol. 56, no 6, p. 3290-3299.
- ANNIS, Antonio, NARDI, Fernando, PETROSELLI, Andrea, APOLLONIO, Ciro, ARCANGELETTI, Ettore, TAURO, Flavia, BELLI, Claudio, BIANCONI, Roberto et GRIMALDI, Salvatore, 2020. UAV-DEMs for Small-Scale Flood Hazard Mapping. *Water*. 16 juin 2020. Vol. 12, n° 6, pp. 1717. DOI 10.3390/w12061717.
- ARONICA, G., BATES, P. D. et HORRITT, M. S., 2002. Assessing the uncertainty in distributed model predictions using observed binary pattern information within GLUE. *Hydrological Processes*. juillet 2002. Vol. 16, n° 10, pp. 2001-2016. DOI 10.1002/hyp.398.
- BAATZ, Martin et SCHÄPE, Arno, [sans date]. Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation. . pp. 12.
- BAGNARDI, Marco, GONZÁLEZ, Pablo J. et HOOPER, Andrew, 2016. High-resolution digital elevation model from tri-stereo Pleiades-1 satellite imagery for lava flow volume

estimates at Fogo Volcano: TRI-STEREO PLEIADES DEM OF FOGO VOLCANO. *Geophysical Research Letters*. 28 juin 2016. Vol. 43, n° 12, pp. 6267-6275. DOI 10.1002/2016GL069457.

BALICA, S.F., POPESCU, I., BEEVERS, L. et WRIGHT, N.G., 2013. Parametric and physically based modelling techniques for flood risk and vulnerability assessment: A comparison. *Environmental Modelling & Software*. mars 2013. Vol. 41, pp. 84-92. DOI 10.1016/j.envsoft.2012.11.002.

BALICA, Stefania et WRIGHT, Nigel G., 2010. Reducing the complexity of the flood vulnerability index. *Environmental Hazards*. 1 décembre 2010. Vol. 9, n° 4, pp. 321-339. DOI 10.3763/ehaz.2010.0043.

BALLESTEROS, J. A., BODOQUE, J. M., DÍEZ-HERRERO, A., et al. Calibration of floodplain roughness and estimation of flood discharge based on tree-ring evidence and hydraulic modelling. *Journal of Hydrology*, 2011, vol. 403, no 1-2, p. 103-115.

BARTHOLOME, Etienne et BELWARD, Allan S. GLC2000: a new approach to global land cover mapping from Earth observation data. *International Journal of Remote Sensing*, 2005, vol. 26, no 9, p. 1959-1977.

BATES, Paul D., DAWSON, Richard J., HALL, Jim W., et al. Simplified two-dimensional numerical modelling of coastal flooding and example applications. *Coastal Engineering*, 2005, vol. 52, no 9, p. 793-810.

BELGIU, Mariana et CSILLIK, Ovidiu, 2018. Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. *Remote Sensing of Environment*. janvier 2018. Vol. 204, pp. 509-523. DOI 10.1016/j.rse.2017.10.005.

BELGIU, Mariana et DRĂGUȚ, Lucian, 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*. avril 2016. Vol. 114, pp. 24-31. DOI 10.1016/j.isprsjprs.2016.01.011.

BELLO, Olalekan Mumin et AINA, Yusuf Adedoyin, 2014. Satellite Remote Sensing as a Tool in Disaster Management and Sustainable Development: Towards a Synergistic Approach. *Procedia - Social and Behavioral Sciences*. mars 2014. Vol. 120, pp. 365-373. DOI 10.1016/j.sbspro.2014.02.114.

BENNANI, Oumaima, TRAMBLAY, Yves, EL MEHDI, Saidi Mohamed, GASCOIN, Simon, et LEONE, Frederic, 2019. Flood Hazard Mapping Using Two Digital Elevation Models: Application in a Semi-Arid Environment of Morocco. *European Scientific Journal ESJ* [en ligne]. 30 novembre 2019. Vol. 15, n° 33. DOI 10.19044/esj.2019.v15n33p338.

BEVEN, K. J., 1985. Distributed models. In Anderson, M., G., Burt, T., P., eds. *Hydrological forecasting*. Chichester (Wiley), pp. 405-436.

BEVEN, K. J., (2000). *Rainfall - runoff modelling*. The Primer. Chichester (Wiley).

BLACKIE, J. R., EELES, C. W. O., 1985. Lumped catchment models. In Anderson, M., G., Burt, T., P., eds. *Hydrological forecasting*. Chichester (Wiley), pp. 311-346.

BLASCHKE, T., 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*. janvier 2010. Vol. 65, n° 1, pp. 2-16. DOI 10.1016/j.isprsjprs.2009.06.004.

BLASCHKE, Thomas, HAY, Geoffrey J., KELLY, Maggi, LANG, Stefan, HOFMANN, Peter, ADDINK, Elisabeth, QUEIROZ FEITOSA, Raul, VAN DER MEER, Freek, VAN DER WERFF, Harald, VAN COILLIE, Fieke et TIEDE, Dirk, 2014. Geographic Object-Based Image Analysis – Towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*. janvier 2014. Vol. 87, pp. 180-191. DOI 10.1016/j.isprsjprs.2013.09.014.

BOVIK, A., HUANG, T. S., et MUNSON, D. A generalization of median filtering using linear combinations of order statistics. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1983, vol. 31, no 6, p. 1342-1350.

BREIMAN, Leo. Random forests. *Machine learning*, 2001, vol. 45, no 1, p. 5-32.

BRUNNER, Gary W. HEC-RAS river analysis system 2D modeling user's manual. US Army Corps of Engineers—Hydrologic Engineering Center, 2016, p. 1-171.

BURGES, Christopher J C, 1998. A Tutorial on Support Vector Machines for Pattern Recognition. . pp. 43.

CAO, Han, ZHANG, Hong, WANG, Chao, et al. Operational flood detection using Sentinel-1 SAR data over large areas. *Water*, 2019, vol. 11, no 4, p. 786.

CASAS, A., BENITO, G., THORNDYCRAFT, V.R. et RICO, M., 2006. The topographic data source of digital terrain models as a key element in the accuracy of hydraulic flood modelling. *Earth Surface Processes and Landforms*. 15 avril 2006. Vol. 31, n° 4, pp. 444-456. DOI 10.1002/esp.1278.

CASTILLEJO-GONZÁLEZ, Isabel Luisa, LÓPEZ-GRANADOS, Francisca, GARCÍA-FERRER, Alfonso, PEÑA-BARRAGÁN, José Manuel, JURADO-EXPÓSITO, Montserrat, DE LA ORDEN, Manuel Sánchez et GONZÁLEZ-AUDICANA, María, 2009. Object- and pixel-based analysis for mapping crops and their agro-environmental associated measures using QuickBird imagery. *Computers and Electronics in Agriculture*. octobre 2009. Vol. 68, n° 2, pp. 207-215. DOI 10.1016/j.compag.2009.06.004.

CAVAYAS, François. Possibilités et limites des images satellites TM LANDSAT en matière d'occupation du sol: le cas de Montréal (Québec). *Cahiers de géographie du Québec*, 1991, vol. 35, no 94, p. 137-151.

CHASTAN, Bernard, GILARD, O., GIVONE, Pierrick, et al. La prise en compte du risque d'inondation. *Ingénieries eau-agriculture-territoires*, 1995, no 2, p. p. 13-p. 20.

CHEHATA, Nesrine, GHARIANI, Karim, BRIS, Arnaud Le et LAGACHERIE, Philippe, 2015. DÉLIMITATION DES PARCELLES AGRICOLES PAR CLASSIFICATION D'IMAGES PLÉIADES. . 2015. pp. 8.

CHEN, Yangyang, MING, Dongping et LV, Xianwei, 2019. Superpixel based land cover classification of VHR satellite image combining multi-scale CNN and scale parameter estimation. *Earth Science Informatics*. septembre 2019. Vol. 12, n° 3, pp. 341-363. DOI 10.1007/s12145-019-00383-2.

- CHEN, Gang, HAY, Geoffrey J., CARVALHO, Luis M. T. et WULDER, Michael A., 2012. Object-based change detection. *International Journal of Remote Sensing*. 20 juillet 2012. Vol. 33, n° 14, pp. 4434-4457. DOI 10.1080/01431161.2011.648285.
- CHI, Mingmin, FENG, Rui et BRUZZONE, Lorenzo, 2008. Classification of hyperspectral remote-sensing data with primal SVM for small-sized training dataset problem. *Advances in Space Research*. 2008. Vol. 41, n° 11, pp. 1793-1799. DOI 10.1016/j.asr.2008.02.012.
- Chow, V.T., Maidment, D.R. et Mays, L.W, Applied Hydrology, McGraw-Hill, Amsterdam, Netherlands, 1988 .
- CHUST, G., DUCROT, D. et PRETUS, J. Ll., 2004. Land cover discrimination potential of radar multitemporal series and optical multispectral images in a Mediterranean cultural landscape. *International Journal of Remote Sensing*. septembre 2004. Vol. 25, n° 17, pp. 3513-3528. DOI 10.1080/0143116032000160480.
- CLERICI, Nicola, VALBUENA CALDERÓN, Cesar Augusto et POSADA, Juan Manuel, 2017. Fusion of Sentinel-1A and Sentinel-2A data for land cover mapping: a case study in the lower Magdalena region, Colombia. *Journal of Maps*. 30 novembre 2017. Vol. 13, n° 2, pp. 718-726. DOI 10.1080/17445647.2017.1372316.
- COBURN, Andrew W., et al. Introduction of a vulnerability assessment system to development planning. In : Disaster Management in Metropolitan Areas for the 21st Century: Proceedings of the IDNDR Aichi/Nagoya International Conference 1993 Japan. 1994. p. 261-70.
- COHEN, Jacob. A coefficient of agreement for nominal scales. *Educational and psychological measurement*, 1960, vol. 20, no 1, p. 37-46.
- CONGALTON, Russell G. Remote sensing and geographic information system data integration: error sources and. *Photogrammetric Engineering & Remote Sensing*, 1991, vol. 57, no 6, p. 677-687.
- CORBANE, Christina, FAURE, Jean-François, BAGHDADI, Nicolas, VILLENEUVE, Nicolas et PETIT, Michel, 2008. Rapid Urban Mapping Using SAR/Optical Imagery Synergy. *Sensors*. 12 novembre 2008. Vol. 8, n° 11, pp. 7125-7143. DOI 10.3390/s8117125.
- CORTES, Corinna et VAPNIK, Vladimir. Support-vector networks. *Machine learning*, 1995, vol. 20, no 3, p. 273-297.
- CREACH, Axel, 2016. Cartographie et analyse économique de la vulnérabilité du littoral atlantique français face au risque de submersion marine. . pp. 449.
- CSILLIK, Ovidiu, CHERBINI, John, JOHNSON, Robert, LYONS, Andy et KELLY, Maggi, 2018. Identification of Citrus Trees from Unmanned Aerial Vehicle Imagery Using Convolutional Neural Networks. *Drones*. 20 novembre 2018. Vol. 2, n° 4, pp. 39. DOI 10.3390/drones2040039.
- DABIJA, Anca, KLUCZEK, Marcin, ZAGAJEWSKI, Bogdan, RACZKO, Edwin, KYCKO, Marlena, AL-SULTTANI, Ahmed H., TARDÀ, Anna, PINEDA, Lydia et CORBERA, Jordi, 2021. Comparison of Support Vector Machines and Random Forests for Corine Land Cover Mapping. *Remote Sensing*. 20 février 2021. Vol. 13, n° 4, pp. 777. DOI 10.3390/rs13040777.

DAS, Apurba et LINDENSCHMIDT, Karl-Erich, 2021. Evaluation of the sensitivity of hydraulic model parameters, boundary conditions and digital elevation models on ice-jam flood delineation. *Cold Regions Science and Technology*. mars 2021. Vol. 183, pp. 103218. DOI 10.1016/j.coldregions.2020.103218.

D'ERCOLE, Robert, THOURET, Jean-Claude, DOLLFUS, Olivier et ASTÉ, Jean-Pierre, 1994. Les vulnérabilités des sociétés et des espaces urbanisés : concepts, typologie, modes d'analyse. *Revue de géographie alpine*. 1994. Vol. 82, n° 4, pp. 87-96. DOI 10.3406/rga.1994.3776.

DESCHAMPS-BERGER, César, GASCOIN, Simon, BERTHIER, Etienne, LACROIX, Pascal et POLIDORI, Laurent, [sans date]. LA TERRE EN 4D: APPORT DES SERIES TEMPORELLES DE MODELES NUMERIQUES D'ELEVATION PAR PHOTOGRAMMETRIE SPATIALE POUR L'ETUDE DE LA SURFACE TERRESTRE. . pp. 14.

DERFOUF FATIHA, 2015. Contribution A L'elaboration D'une Geodatabase Du Reseau Hydrographique Cas /La Region D'ain Temouchent. Mémoire de master. Centre Universitaire Belhejd Bouchaib - Ain Temouchent-

DEVIA, Gayathri K., GANASRI, B. Pa, et DWARAKISH, G. Sa. A review on hydrological models. *Aquatic procedia*, 2015, vol. 4, p. 1001-1007.

DU, Juan, CHENG, Linlin, ZHANG, Qiang, YANG, Yumeng et XU, Wei, 2019. Different Flooding Behaviors Due to Varied Urbanization Levels within River Basin: A Case Study from the Xiang River Basin, China. *International Journal of Disaster Risk Science*. mars 2019. Vol. 10, n° 1, pp. 89-102. DOI 10.1007/s13753-018-0195-4.

DURO, Dennis C., FRANKLIN, Steven E. et DUBÉ, Monique G., 2012. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. *Remote Sensing of Environment*. mars 2012. Vol. 118, pp. 259-272. DOI 10.1016/j.rse.2011.11.020.

DUSSEUX, Pauline, CORPETTI, Thomas, HUBERT-MOY, Laurence et CORGNE, Samuel, 2014. Combined Use of Multi-Temporal Optical and Radar Satellite Images for Grassland Monitoring. *Remote Sensing*. 30 juin 2014. Vol. 6, n° 7, pp. 6163-6182. DOI 10.3390/rs6076163.

eCognition, 2021. [en ligne]. Disponible à l'adresse : <https://fr.geospatial.trimble.com/products-and-solutions/ecognition>

ESA, https://www.esa.int/Space_in_Member_States/France.

ETTRITCH, Georgina, HARDY, Andy, BOJANG, Landing, CROSS, Dónall, BUNTING, Peter et BREWER, Paul, 2018. Enhancing digital elevation models for hydraulic modelling using flood frequency detection. *Remote Sensing of Environment*. novembre 2018. Vol. 217, pp. 506-522. DOI 10.1016/j.rse.2018.08.029.

FAO (2002): Land tenure and rural development. FAO Land Tenure Studies 3, Rome.

FARJAD, Babak, GUPTA, Anil, RAZAVI, Saman, FARAMARZI, Monireh et MARCEAU, Danielle, 2017. An Integrated Modelling System to Predict Hydrological Processes under Climate and Land-Use/Cover Change Scenarios. *Water*. 9 octobre 2017. Vol. 9, n° 10, pp. 767. DOI 10.3390/w9100767.

FATHY, Ismail, ABD-ELHAMID, Hany, ZELENKOVA, Martina et KAPOZTASOVA, Daniela, 2019. Effect of Topographic Data Accuracy on Watershed Management. *International Journal of Environmental Research and Public Health*. 1 novembre 2019. Vol. 16, n° 21, pp. 4245. DOI 10.3390/ijerph16214245.

FEIZIZADEH, Bakhtiar, OMARZADEH, Davoud, KAZEMI GARAJEH, Mohammad, LAKES, Tobia et BLASCHKE, Thomas, 2021. Machine learning data-driven approaches for land use/cover mapping and trend analysis using Google Earth Engine. *Journal of Environmental Planning and Management*. 23 novembre 2021. pp. 1-33. DOI 10.1080/09640568.2021.2001317.

FEKETE, Alexander, DAMM, Marion, et BIRKMANN, Jörn. Scales as a challenge for vulnerability assessment. *Natural Hazards*, 2010, vol. 55, no 3, p. 729-747.

FLOODsite (2006). "Guidelines for socio-economic flood damage evaluation. FLOODsite project Report number T9-06-01.", <<http://www.floodsite.net/default.htm>>.

FOHRER, N., HAVERKAMP, S. et FREDE, H.-G., 2005. Assessment of the effects of land use patterns on hydrologic landscape functions: development of sustainable land use concepts for low mountain range areas. *Hydrological Processes*. 28 février 2005. Vol. 19, n° 3, pp. 659-672. DOI 10.1002/hyp.5623.

FOODY, Giles M., 2002. Status of land cover classification accuracy assessment. *Remote Sensing of Environment*. avril 2002. Vol. 80, n° 1, pp. 185-201. DOI 10.1016/S0034-4257(01)00295-4.

FOODY, G.M. et MATHUR, A., 2004. A relative evaluation of multiclass image classification by support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*. juin 2004. Vol. 42, n° 6, pp. 1335-1343. DOI 10.1109/TGRS.2004.827257.

FRANKLIN, S. E. et WULDER, M. A. Remote sensing methods in medium spatial resolution satellite data land cover classification of large areas. *Progress in Physical Geography*, 2002, vol. 26, no 2, p. 173-205.

GARG, Vaibhav, NIKAM, Bhaskar Ramchandra, THAKUR, Praveen Kumar, AGGARWAL, Shiv Prasad, GUPTA, Prasun Kumar et SRIVASTAV, Sushil Kumar, 2019. Human-induced land use land cover change and its impact on hydrology. *HydroResearch*. juin 2019. Vol. 1, pp. 48-56. DOI 10.1016/j.hydres.2019.06.001.

GAUCI, Alys A., BRODBECK, Christian J., PONCET, Aurelie M. et KNAPPENBERGER, Thorsten, 2018. Assessing the Geospatial Accuracy of Aerial Imagery Collected with Various UAS Platforms. *Transactions of the ASABE*. 2018. Vol. 61, n° 6, pp. 1823-1829. DOI 10.13031/trans.12852.

Gaume E, Marco B, Llassat MC, Maouche S, Lang M, et Diakakis M., 2016. Mediterranean Extreme Floods and Flash Floods. *A Scientific Update, IRD Editions, pp.133-144, 2016, Coll. Synthèses, 978-2-7099-2219-7. hal-01465740v2*

GEBREMICAEL, T.G., MOHAMED, Y.A. et VAN DER ZAAG, P., 2019. Attributing the hydrological impact of different land use types and their long-term dynamics through combining parsimonious hydrological modelling, alteration analysis and PLSR analysis. *Science of The Total Environment*. avril 2019. Vol. 660, pp. 1155-1167. DOI 10.1016/j.scitotenv.2019.01.085.

GEORGANOS, Stefanos, GRIPPA, Tais, VANHUYSSE, Sabine, LENNERT, Moritz, SHIMONI, Michal, KALOGIROU, Stamatis et WOLFF, Eleonore, 2018. Less is more: optimizing classification performance through feature selection in a very-high-resolution remote sensing object-based urban application. *GIScience & Remote Sensing*. 4 mars 2018. Vol. 55, n° 2, pp. 221-242. DOI 10.1080/15481603.2017.1408892.

GILLEY, John E. et FINKNER, S. C. Hydraulic roughness coefficients as affected by random roughness. *Transactions of the ASAE*, 1991, vol. 34, no 3, p. 897-0903.

GHAYOUR, Laleh, NESHAT, Aminreza, PARYANI, Sina, *et al.* Performance evaluation of sentinel-2 and landsat 8 OLI data for land cover/use classification using a comparison between machine learning algorithms. *Remote Sensing*, 2021, vol. 13, no 7, p. 1349.

GHORBANZADEH, Omid et BLASCHKE, Thomas, 2019. Optimizing Sample Patches Selection of CNN to Improve the mIOU on Landslide Detection: In : *Proceedings of the 5th International Conference on Geographical Information Systems Theory, Applications and Management* [en ligne]. Heraklion, Crete, Greece : SCITEPRESS - Science and Technology Publications. 2019. pp. 33-40. [Consulté le 18 avril 2022]. ISBN 978-989-758-371-1.

GHORBANZADEH, Omid, TIEDE, Dirk, WENDT, Lorenz, SUDMANN, Martin et LANG, Stefan, 2021. Transferable instance segmentation of dwellings in a refugee camp - integrating CNN and OBIA. *European Journal of Remote Sensing*. 5 février 2021. Vol. 54, n° sup1, pp. 127-140. DOI 10.1080/22797254.2020.1759456.

GHORBANZADEH, Omid, TIEDE, Dirk, WENDT, Lorenz, SUDMANN, Martin et LANG, Stefan, 2021. Transferable instance segmentation of dwellings in a refugee camp - integrating CNN and OBIA. *European Journal of Remote Sensing*. 5 février 2021. Vol. 54, n° sup1, pp. 127-140. DOI 10.1080/22797254.2020.1759456.

GHOSH, Aniruddha et JOSHI, P.K., 2014. A comparison of selected classification algorithms for mapping bamboo patches in lower Gangetic plains using very high resolution WorldView 2 imagery. *International Journal of Applied Earth Observation and Geoinformation*. février 2014. Vol. 26, pp. 298-311. DOI 10.1016/j.jag.2013.08.011.

Giandotti, M., 1934. Previsione delle piene e delle magre dei corsi d'acqua. Istituto Poligrafico dello Stato, 8, 107-117.

GONG, Peng, WANG, Jie, YU, Le, et al. Finer resolution observation and monitoring of global land cover: First mapping results with Landsat TM and ETM+ data. *International Journal of Remote Sensing*, 2013, vol. 34, no 7, p. 2607-2654.

Gómez, Christina. (2016). Optical Remotely Sensed Time Series Data for Land Cover Classification: A Review. *ISPRS Journal of Photogrammetry and Remote Sensing*.

GROHMANN, Carlos H., 2018. Evaluation of TanDEM-X DEMs on selected Brazilian sites: Comparison with SRTM, ASTER GDEM and ALOS AW3D30. *Remote Sensing of Environment*. juin 2018. Vol. 212, pp. 121-133. DOI 10.1016/j.rse.2018.04.043.

GUAN, DongJie, LI, HaiFeng, INOHAE, Takuro, SU, Weici, NAGAIE, Tadashi et HOKAO, Kazunori, 2011. Modeling urban land use change by the integration of cellular automaton and Markov model. *Ecological Modelling*. octobre 2011. Vol. 222, n° 20-22, pp. 3761-3772. DOI 10.1016/j.ecolmodel.2011.09.009.

HAACK, Barry N. Landsat: A tool for development. *World Development*, 1982, vol. 10, no 10, p. 899-909.

HALMY, Marwa Waseem A., GESSLER, Paul E., HICKE, Jeffrey A. et SALEM, Boshra B., 2015. Land use/land cover change detection and prediction in the north-western coastal desert of Egypt using Markov-CA. *Applied Geography*. septembre 2015. Vol. 63, pp. 101-112. DOI 10.1016/j.apgeog.2015.06.015.

HANSEN, Matthew C., DEFRIES, Ruth S., TOWNSHEND, John RG, et al. Global land cover classification at 1 km spatial resolution using a classification tree approach. *International journal of remote sensing*, 2000, vol. 21, no 6-7, p. 1331-1364.

HEROLD, Martin, LIU, XiaoHang, et CLARKE, Keith C. Spatial metrics and image texture for mapping urban land use. *Photogrammetric Engineering & Remote Sensing*, 2003, vol. 69, no 9, p. 991-1001.

HERYADI, Yaya et MIRANDA, Eka, 2020. Land Cover Classification Based on Sentinel-2 Satellite Imagery Using Convolutional Neural Network Model: A Case Study in Semarang Area, Indonesia. In : HUK, Maciej, MALESZKA, Marcin et SZCZERBICKI, Edward (éd.), *Intelligent Information and Database Systems: Recent Developments* [en ligne]. Cham : Springer International Publishing. pp. 191-206. Studies in Computational Intelligence. [Consulté le 13 janvier 2022]. ISBN 978-3-030-14131-8. Disponible à l'adresse : http://link.springer.com/10.1007/978-3-030-14132-5_15

HOW JIN AIK, Darren, ISMAIL, Mohd Hasmadi et MUHARAM, Farrah Melissa, 2020. Land Use/Land Cover Changes and the Relationship with Land Surface Temperature Using Landsat and MODIS Imageries in Cameron Highlands, Malaysia. *Land*. 5 octobre 2020. Vol. 9, n° 10, pp. 372. DOI 10.3390/land9100372.

HONG, S.-H et WDOWINSKI, S., 2014. Multitemporal Multitrack Monitoring of Wetland Water Levels in the Florida Everglades Using ALOS PALSAR Data With Interferometric Processing. *IEEE Geoscience and Remote Sensing Letters*. août 2014. Vol. 11, n° 8, pp. 1355-1359. DOI 10.1109/LGRS.2013.2293492.

HOQUE, Muhammad, TASFIA, Saima, AHMED, Naser et PRADHAN, Biswajeet, 2019. Assessing Spatial Flood Vulnerability at Kalapara Upazila in Bangladesh Using an Analytic Hierarchy Process. *Sensors*. 15 mars 2019. Vol. 19, n° 6, pp. 1302. DOI 10.3390/s19061302.

HOSTACHE, R, 2006. Analyse d'images satellitaires d'inondations pour la caractérisation tridimensionnelle de l'aléa et l'aide à la modélisation hydraulique. . pp. 257.

HOUSE, Frederick B., GRUBER, Arnold, HUNT, Garry E., et al. History of satellite missions and measurements of the Earth radiation budget (1957–1984). *Reviews of geophysics*, 1986, vol. 24, no 2, p. 357-377.

HTITIOU, Abdelaziz, BOUDHAR, Abdelghani, LEBRINI, Youssef, HADRIA, Rachid, LIONBOUI, Hayat, ELMANSOURI, Loubna, TYCHON, Bernard et BENABDELOUAHAB, Tarik, 2019. The Performance of Random Forest Classification Based on Phenological Metrics Derived from Sentinel-2 and Landsat 8 to Map Crop Cover in an Irrigated Semi-arid Region. *Remote Sensing in Earth Systems Sciences*. décembre 2019. Vol. 2, n° 4, pp. 208-224. DOI 10.1007/s41976-019-00023-9.

HUANG, C., DAVIS, L. S. et TOWNSHEND, J. R. G., 2002. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*. janvier 2002. Vol. 23, n° 4, pp. 725-749. DOI 10.1080/01431160110040323.

HUANG, Heng, LEGARSKY, Justin et OTHMAN, Maslina, 2007. Land-cover Classification Using Radarsat and Landsat Imagery for St. Louis, Missouri. *Photogrammetric Engineering & Remote Sensing*. 1 janvier 2007. Vol. 73, n° 1, pp. 37-43. DOI 10.14358/PERS.73.1.37.

Huete, A, K Didan, T Miura, E.P Rodriguez, X Gao, et L.G Ferreira. (2002). Overview of the Radiometric and Biophysical Performance of the MODIS Vegetation Indices. *Remote Sensing of Environment* 83 (1-2) : 195-213 [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2).

IENCO, Dino, INTERDONATO, Roberto, GAETANO, Raffaele et HO TONG MINH, Dinh, 2019. Combining Sentinel-1 and Sentinel-2 Satellite Image Time Series for land cover mapping via a multi-source deep learning architecture. *ISPRS Journal of Photogrammetry and Remote Sensing*. décembre 2019. Vol. 158, pp. 11-22. DOI 10.1016/j.isprsjprs.2019.09.016.

Inglada J, Vincent A, Arias M, et Marais-Sicre C. (2016). Improved Early Crop Type Identification By Joint Use of High Temporal Resolution SAR And Optical Image Time Series. *Remote Sensing* 8 (5): 362. <https://doi.org/10.3390/rs8050362>.

INGLADA, Jordi, VINCENT, Arthur, ARIAS, Marcela, TARDY, Benjamin, MORIN, David et RODES, Isabel, 2017. Operational High Resolution Land Cover Map Production at the Country Scale Using Satellite Image Time Series. *Remote Sensing*. 22 janvier 2017. Vol. 9, n° 1, pp. 95. DOI 10.3390/rs9010095.

JAMALI, Ali, 2021. Land use land cover modeling using optimized machine learning classifiers: a case study of Shiraz, Iran. *Modeling Earth Systems and Environment*. septembre 2021. Vol. 7, n° 3, pp. 1539-1550. DOI 10.1007/s40808-020-00859-x.

JIN, Baoxuan, YE, Peng, ZHANG, Xueying, SONG, Weiwei et LI, Shihua, 2019a. Object-Oriented Method Combined with Deep Convolutional Neural Networks for Land-Use-Type Classification of Remote Sensing Images. *Journal of the Indian Society of Remote Sensing*. juin 2019. Vol. 47, n° 6, pp. 951-965. DOI 10.1007/s12524-019-00945-3.

JIN, Baoxuan, YE, Peng, ZHANG, Xueying, SONG, Weiwei et LI, Shihua, 2019b. Object-Oriented Method Combined with Deep Convolutional Neural Networks for Land-Use-Type Classification of Remote Sensing Images. *Journal of the Indian Society of Remote Sensing*. juin 2019. Vol. 47, n° 6, pp. 951-965. DOI 10.1007/s12524-019-00945-3.

JOSHI, Neha, BAUMANN, Matthias, EHAMMER, Andrea, FENSHOLT, Rasmus, GROGAN, Kenneth, HOSTERT, Patrick, JEPSEN, Martin, KUEMMERLE, Tobias, MEYFROIDT, Patrick, MITCHARD, Edward, REICHE, Johannes, RYAN, Casey et WASKE, Björn, 2016. A Review of the Application of Optical and Radar Remote Sensing Data Fusion to Land Use Mapping and Monitoring. *Remote Sensing*. 16 janvier 2016. Vol. 8, n° 1, pp. 70. DOI 10.3390/rs8010070.

JUCKER, Tommaso, CASPERSEN, John, CHAVE, Jérôme, et al. Allometric equations for integrating remote sensing imagery into forest monitoring programmes. *Global change biology*, 2017, vol. 23, no 1, p. 177-190.

KASTALI, Abdennour, 2021. Design Flood and Flood-Prone Areas under Rating Curve Uncertainty: Area of Vieux-Ténès, Algeria. *J. Hydrol. Eng.* pp. 12.

KAZAKIS, Nerantzis, KOUGIAS, Ioannis et PATSIALIS, Thomas, 2015. Assessment of flood hazard areas at a regional scale using an index-based approach and Analytical Hierarchy Process: Application in Rhodope–Evros region, Greece. *Science of The Total Environment*. décembre 2015. Vol. 538, pp. 555-563. DOI 10.1016/j.scitotenv.2015.08.055.

KHATAMI, Reza, MOUNTRAKIS, Giorgos et STEHMAN, Stephen V., 2016. A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research. *Remote Sensing of Environment*. mai 2016. Vol. 177, pp. 89-100. DOI 10.1016/j.rse.2016.02.028.

KNORN, Jan, RABE, Andreas, RADELOFF, Volker C., KUEMMERLE, Tobias, KOZAK, Jacek et HOSTERT, Patrick, 2009. Land cover mapping of large areas using chain classification of neighboring Landsat satellite images. *Remote Sensing of Environment*. mai 2009. Vol. 113, n° 5, pp. 957-964. DOI 10.1016/j.rse.2009.01.010.

KOSIOROWSKI, Daniel, RYDLEWSKI, Jerzy P., et SNARSKA, Małgorzata. Detecting a structural change in functional time series using local Wilcoxon statistic. *Statistical Papers*, 2019, vol. 60, no 5, p. 1677-1698.

KREIBICH, H., PIROTH, K., SEIFERT, I., MAIWALD, H., KUNERT, U., SCHWARZ, J., MERZ, B. et THIEKEN, A. H., 2009. Is flow velocity a significant parameter in flood damage modelling? *Natural Hazards and Earth System Sciences*. 14 octobre 2009. Vol. 9, n° 5, pp. 1679-1692. DOI 10.5194/nhess-9-1679-2009.

KUSSUL, Nataliia, LAVRENIUK, Mykola, SKAKUN, Sergii, et al. Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 2017, vol. 14, no 5, p. 778-782.

LACINA, Traoré. *Analyse des refoulements dans les réseaux de drainage urbain*. 2012. Thèse de doctorat. École de technologie supérieure.

LACROIX, Pascal, BERTHIER, Etienne et MAQUERHUA, Edu Taipei, 2015. Earthquake-driven acceleration of slow-moving landslides in the Colca valley, Peru, detected from Pléiades images. *Remote Sensing of Environment*. août 2015. Vol. 165, pp. 148-158. DOI 10.1016/j.rse.2015.05.010.

LAMICHHANE, Niraj et SHARMA, Suresh, 2018. Effect of input data in hydraulic modeling for flood warning systems. *Hydrological Sciences Journal*. 26 avril 2018. Vol. 63, n° 6, pp. 938-956. DOI 10.1080/02626667.2018.1464166.

LANARI, Riccardo, BONANO, Manuela, CASU, Francesco, et al. Automatic generation of sentinel-1 continental scale DInSAR deformation time series through an extended P-SBAS processing pipeline in a cloud computing environment. *Remote Sensing*, 2020, vol. 12, no 18, p. 2961.

LAWRENCE, Rick L., WOOD, Shana D. et SHELEY, Roger L., 2006. Mapping invasive plants using hyperspectral imagery and Breiman Cutler classifications (randomForest). *Remote Sensing of Environment*. février 2006. Vol. 100, n° 3, pp. 356-362. DOI 10.1016/j.rse.2005.10.014.

LEE, Jong-Sen. Digital image smoothing and the sigma filter. *Computer vision, graphics, and image processing*, 1983, vol. 24, no 2, p. 255-269.

LEE, Jong-Sen, GRUNES, Mitchell R., AINSWORTH, Thomas L., et al. Unsupervised classification using polarimetric decomposition and the complex Wishart classifier. *IEEE Transactions on Geoscience and Remote Sensing*, 1999, vol. 37, no 5, p. 2249-2258.

LEBOURGEOIS, Valentine, DUPUY, Stéphane, VINTROU, Élodie, et al. A combined random forest and OBIA classification scheme for mapping smallholder agriculture at different nomenclature levels using multisource data (simulated Sentinel-2 time series, VHRS and DEM). *Remote Sensing*, 2017, vol. 9, no 3, p. 259.

LI, Mengmeng, STEIN, Alfred, BIJKER, Wietske, *et al.* Urban land use extraction from Very High Resolution remote sensing imagery using a Bayesian network. *ISPRS journal of photogrammetry and remote sensing*, 2016, vol. 122, p. 192-205.

LI, H.Y., MAN, W.D., LI, X.Y., REN, C.Y., WANG, Z.M., LI, L., JIA, M.M. et MAO, D.H., 2017. Remote sensing investigation of anthropogenic land cover expansion in the low-elevation coastal zone of Liaoning Province, China. *Ocean & Coastal Management*. novembre 2017. Vol. 148, pp. 245-259. DOI 10.1016/j.ocecoaman.2017.08.007.

LI, Mengmeng, STEIN, Alfred, et DE BEURS, Kirsten M. A Bayesian characterization of urban land use configurations from VHR remote sensing images. *International Journal of Applied Earth Observation and Geoinformation*, 2020, vol. 92, p. 102175.

LIAW, Andy, WIENER, Matthew, *et al.* Classification and regression by randomForest. *R news*, 2002, vol. 2, no 3, p. 18-22.

LIU, Shengjie, QI, Zhixin, LI, Xia et YEH, Anthony, 2019. Integration of Convolutional Neural Networks and Object-Based Post-Classification Refinement for Land Use and Land Cover Mapping with Optical and SAR Data. *Remote Sensing*. 22 mars 2019. Vol. 11, n° 6, pp. 690. DOI 10.3390/rs11060690.

LIU, B., DU, S. et ZHANG, X., 2020. LAND COVER CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK WITH REMOTE SENSING DATA AND DIGITAL SURFACE MODEL. *ISPRS Annals of the Photogrammetry, Remote Sensing and*

Spatial Information Sciences. 3 août 2020. Vol. V-3-2020, pp. 39-43. DOI 10.5194/isprs-annals-V-3-2020-39-2020.

LOURENÇO, P., TEODORO, A.C., GONÇALVES, J.A., HONRADO, J.P., CUNHA, M. et SILLERO, N., 2021. Assessing the performance of different OBIA software approaches for mapping invasive alien plants along roads with remote sensing data. *International Journal of Applied Earth Observation and Geoinformation*. mars 2021. Vol. 95, pp. 102263. DOI 10.1016/j.jag.2020.102263.

LOVELAND, Thomas R. et BELWARD, A. S. The IGBP-DIS global 1km land cover data set, DISCover: first results. *International Journal of Remote Sensing*, 1997, vol. 18, no 15, p. 3289-3295.

MA, Lei, SCHMITT, Michael et ZHU, Xiaoxiang, 2020. Uncertainty Analysis of Object-Based Land-Cover Classification Using Sentinel-2 Time-Series Data. *Remote Sensing*. 19 novembre 2020. Vol. 12, n° 22, pp. 3798. DOI 10.3390/rs12223798.

MAGGIORI, Emmanuel, TARABALKA, Yuliya, CHARPIAT, Guillaume et ALLIEZ, Pierre, 2017. Convolutional Neural Networks for Large-Scale Remote-Sensing Image Classification. *IEEE Transactions on Geoscience and Remote Sensing*. février 2017. Vol. 55, n° 2, pp. 645-657. DOI 10.1109/TGRS.2016.2612821.

MARTIMORT, Philippe, ARINO, Olivier, BERGER, Michael, et al. Sentinel-2 optical high resolution mission for GMES operational services. In : 2007 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2007. p. 2677-2680.

MAHER, J., ZHANG, Y., et WANG, H. A performance evaluation of σ / Δ - STAP approach to airborne surveillance radars in the presence of both clutter and jammers. In : Radar 97 (Conf. Publ. No. 449). IET, 1997. p. 305-309.

MAHATO, Susanta, PAL, Swades, TALUKDAR, Swapan, SAHA, Tamal Kanti et MANDAL, Parikshit, 2021. Field based index of flood vulnerability (IFV): A new validation technique for flood susceptible models. *Geoscience Frontiers*. septembre 2021. Vol. 12, n° 5, pp. 101175. DOI 10.1016/j.gsf.2021.101175.

MAHDIANPARI, Masoud, SALEHI, Bahram, REZAEE, Mohammad, MOHAMMADIMANESH, Fariba et ZHANG, Yun, 2018. Very Deep Convolutional Neural Networks for Complex Land Cover Mapping Using Multispectral Remote Sensing Imagery. *Remote Sensing*. 14 juillet 2018. Vol. 10, n° 7, pp. 1119. DOI 10.3390/rs10071119.

MANTERO, Paolo, MOSER, Gabriele, et SERPICO, Sebastiano B. Partially supervised classification of remote sensing images through SVM-based probability density estimation. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, vol. 43, no 3, p. 559-570.

MARANT, L (2009) Comparaison entre la modélisation de la rivière unidimensionnelle (1D) et bidimensionnelle (2D) en vue d'une modélisation de la basse vallée de Doller, mémoire fin d'étude. Ecole nationale de Génie de de l'eau et de l'environnement de Strasbourg (<https://www.yumpu.com/fr/document/view/31464527/comparaison-entre-la-modacalisation-de-riviere-engees>)

MÅRD, Johanna, DI BALDASSARRE, Giuliano, et MAZZOLENI, Maurizio. Nighttime light data reveal how flood protection shapes human proximity to rivers. *Science Advances*, 2018, vol. 4, no 8, p. eaar5779.

MARTINIS, Sandro, PLANK, Simon, et ČWIK, Kamila. The use of Sentinel-1 time-series data to improve flood monitoring in arid areas. *Remote Sensing*, 2018, vol. 10, no 4, p. 583.

MAS, J.-F., 1999. Monitoring land-cover changes: A comparison of change detection techniques. *International Journal of Remote Sensing*. janvier 1999. Vol. 20, n° 1, pp. 139-152. DOI 10.1080/014311699213659.

MAUREL, Pierre, RACLOT, Damien, PUECH, Christian et CEMAGREF, S, [sans date]. Apports de la télédétection à très haute résolution spatiale à l'étude du risque d'inondation. . pp. 17.

MAZZIA, Vittorio, KHALIQ, Aleem et CHIABERGE, Marcello, 2019. Improvement in Land Cover and Crop Classification based on Temporal Features Learning from Sentinel-2 Data Using Recurrent-Convolutional Neural Network (R-CNN). *Applied Sciences*. 28 décembre 2019. Vol. 10, n° 1, pp. 238. DOI 10.3390/app10010238.

MEDD (Ministère de l'Ecologie et du Développement Durable)-FRANCE., 2004b. Analyse des Risques et Prévention des Accidents Majeurs (DRA-34). Rapport Partiel d'Opération f Guide pour la prise en compte du risque inondation (*Version 2004*). 82 p.

MEDD-PRIM@., 2009. *Portail de la prévention des risques majeurs* [en ligne]. Ministère de l'écologie et du développement durable. [réf. du 12 octobre 2013]. Disponible sur : <http://www.prim.net/>.

MEEDDAT., 2008. *AIDA, la réglementation des activités à risque* [en ligne]. In Circulaire du 02/10/2003 relative aux mesures d' application immédiate introduites par la loi n° 2003-699 en matière de prévention des risques technologiques dans les installations classées. [réf. du 10 octobre 2013]. Disponible sur : <http://www.nord-pas-decalais.developpementdurable.gouv.fr/?Alea>

MCFEETERS, S. K., 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*. mai 1996. Vol. 17, n° 7, pp. 1425-1432. DOI 10.1080/01431169608948714.

MCNAIRN, Heather, CHAMPAGNE, Catherine, SHANG, Jiali, HOLMSTROM, Delmar et REICHERT, Gordon, 2009. Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*. septembre 2009. Vol. 64, n° 5, pp. 434-449. DOI 10.1016/j.isprsjprs.2008.07.006.

MIHU-PINTILIE, Alin, CÎMPIANU, Cătălin Ioan, STOLERIU, Cristian Constantin, PÉREZ, Martín Núñez et PAVELUC, Larisa Elena, 2019. Using High-Density LiDAR Data and 2D Streamflow Hydraulic Modeling to Improve Urban Flood Hazard Maps: A HEC-RAS Multi-Scenario Approach. *Water*. 3 septembre 2019. Vol. 11, n° 9, pp. 1832. DOI 10.3390/w11091832.

MONSALVE-TELLEZ, Jose Manuel, TORRES-LEÓN, Jorge Luis et GARCÉS-GÓMEZ, Yeison Alberto, 2022. Evaluation of SAR and Optical Image Fusion Methods in Oil Palm Crop Cover Classification Using the Random Forest Algorithm. *Agriculture*. 1 juillet 2022. Vol. 12, n° 7, pp. 955. DOI 10.3390/agriculture12070955.

MUSTAFA, Andam et SZYDŁOWSKI, Michał. The impact of spatiotemporal changes in land development (1984–2019) on the increase in the runoff coefficient in Erbil, Kurdistan Region of Iraq. *Remote Sensing*, 2020, vol. 12, no 8, p. 1302.

MYINT, Soe W., GOBER, Patricia, BRAZEL, Anthony, GROSSMAN-CLARKE, Susanne et WENG, Qihao, 2011. Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*. 15 mai 2011. Vol. 115, n° 5, pp. 1145-1161. DOI 10.1016/j.rse.2010.12.017.

NANDAM, Vineela et PATEL, P. L., 2021. A novel hybrid approach using SVM and spectral indices for enhanced land use land cover mapping of coastal urban plains. *Geocarto International*. 22 mars 2021. pp. 1-23. DOI 10.1080/10106049.2021.1899300.

NARIMANE, Zaabar, SIMONA, Niculescu et KAMEL, Mihoubi Mustapha, 2022. Application of convolutional neural networks with object-based image analysis for land cover and land use mapping in coastal areas: A case study in Ain Témouchent, Algeria. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2022. pp. 1-16. DOI 10.1109/JSTARS.2022.3185185.

NASA/EO (Earth Observatory), 2005. Great flood of the Mississippi River, 1993. <http://earthobservatory.nasa.gov/IOTD/view.php?id=5422>

NICULESCU SR, Simona, BILLEY, Antoine, et TALAB-OU-ALI JR, Halima. Random forest classification using Sentinel-1 and Sentinel-2 series for vegetation monitoring in the Pays de Brest (France). In : *Remote Sensing for Agriculture, Ecosystems, and Hydrology XX*. SPIE, 2018. p. 1078305.

NICULESCU, Simona, BOISSONNAT, Jean-Baptiste, LARDEUX, Cédric, ROBERTS, Dar, HANGANU, Jenica, BILLEY, Antoine, CONSTANTINESCU, Adrian et DOROFTEI, Mihai, 2020. Synergy of High-Resolution Radar and Optical Images Satellite for Identification and Mapping of Wetland Macrophytes on the Danube Delta. *Remote Sensing*. 8 juillet 2020. Vol. 12, n° 14, pp. 2188. DOI 10.3390/rs12142188.

NKWUNONWO, U. C., WHITWORTH, M., et BAILY, B. A review of the current status of flood modelling for urban flood risk management in the developing countries. *Scientific African*, 2020, vol. 7, p. e00269.

OLAODE, Abass, NAGHDY, Golshah, et TODD, Catherine. Unsupervised classification of images: a review. *International Journal of Image Processing*, 2014, vol. 8, no 5, p. 325-342.

OZDEMIR, Adnan et ALTURAL, Tolga. A comparative study of frequency ratio, weights of evidence and logistic regression methods for landslide susceptibility mapping: Sultan Mountains, SW Turkey. *Journal of Asian Earth Sciences*, 2013, vol. 64, p. 180-197.

Pal M. (2005) Random forest classifier for remote sensing classification, *International Journal of Remote Sensing*, 26:1, 217-222, 10.1080/01431160412331269698.

PAN, Suoyan, GUAN, Haiyan, CHEN, Yating, YU, Yongtao, NUNES GONÇALVES, Wesley, MARCATO JUNIOR, José et LI, Jonathan, 2020a. Land-cover classification of multispectral LiDAR data using CNN with optimized hyper-parameters. *ISPRS Journal of Photogrammetry and Remote Sensing*. août 2020. Vol. 166, pp. 241-254. DOI 10.1016/j.isprsjprs.2020.05.022.

PAN, Suoyan, GUAN, Haiyan, CHEN, Yating, YU, Yongtao, NUNES GONÇALVES, Wesley, MARCATO JUNIOR, José et LI, Jonathan, 2020b. Land-cover classification of multispectral LiDAR data using CNN with optimized hyper-parameters. *ISPRS Journal of Photogrammetry and Remote Sensing*. août 2020. Vol. 166, pp. 241-254. DOI 10.1016/j.isprsjprs.2020.05.022.

PANDE, Shivam et BANERJEE, Biplab, 2021. Adaptive hybrid attention network for hyperspectral image classification. *Pattern Recognition Letters*. avril 2021. Vol. 144, pp. 6-12. DOI 10.1016/j.patrec.2021.01.015.

PARIZI, Esmaeel, KHOJEH, Shokoufeh, HOSSEINI, Seiyed Mossa et MOGHADAM, Yaser Jouybari, 2022. Application of Unmanned Aerial Vehicle DEM in flood modeling and comparison with global DEMs: Case study of Atrak River Basin, Iran. *Journal of Environmental Management*. septembre 2022. Vol. 317, pp. 115492. DOI 10.1016/j.jenvman.2022.115492.

PELLETIER, Charlotte, VALERO, Silvia, INGLADA, Jordi, CHAMPION, Nicolas et DEDIEU, Gérard, 2016. Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas. *Remote Sensing of Environment*. décembre 2016. Vol. 187, pp. 156-168. DOI 10.1016/j.rse.2016.10.010.

PETERS, Jan, VAN COILLIE, Frieke, WESTRA, Toon et DE WULF, Robert, 2011. Synergy of very high resolution optical and radar data for object-based olive grove mapping. *International Journal of Geographical Information Science*. juin 2011. Vol. 25, n° 6, pp. 971-989. DOI 10.1080/13658816.2010.515946.

PIERMATTEI, Livia, MARTY, Mauro, KAREL, Wilfried, et al. Impact of the acquisition geometry of very high-resolution Pléiades imagery on the accuracy of canopy height models over forested alpine regions. *Remote Sensing*, 2018, vol. 10, no 10, p. 1542.

PHIRI, Darius et MORGENROTH, Justin. Developments in Landsat land cover classification methods: A review. *Remote Sensing*, 2017, vol. 9, no 9, p. 967.

PHIRI, Darius, SIMWANDA, Matamy, SALEKIN, Serajis, NYIRENDA, Vincent, MURAYAMA, Yuji et RANAGALAGE, Manjula, 2020. Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing*. 16 juillet 2020. Vol. 12, n° 14, pp. 2291. DOI 10.3390/rs12142291.

PLATT, Rutherford V., OGRA, Monica V., BADOLA, Ruchi et HUSSAIN, Syed Ainal, 2016. Conservation-induced resettlement as a driver of land cover change in India: An object-based trend analysis. *Applied Geography*. avril 2016. Vol. 69, pp. 75-86. DOI 10.1016/j.apgeog.2016.02.006.

PLATT, Rutherford V. et RAPOZA, Lauren, 2008. An Evaluation of an Object-Oriented Paradigm for Land Use/Land Cover Classification*. *The Professional Geographer*. janvier 2008. Vol. 60, n° 1, pp. 87-100. DOI 10.1080/00330120701724152.

PLESKACHEVSKY, Andrey, LEHNER, Susanne, HEEGE, Thomas et MOTT, Claudius, 2011. Synergy and fusion of optical and synthetic aperture radar satellite data for underwater topography estimation in coastal areas. *Ocean Dynamics*. décembre 2011. Vol. 61, n° 12, pp. 2099-2120. DOI 10.1007/s10236-011-0460-1.

POLYKRETIS, Christos, GRILLAKIS, Manolis et ALEXAKIS, Dimitrios, 2020. Exploring the Impact of Various Spectral Indices on Land Cover Change Detection Using Change Vector Analysis: A Case Study of Crete Island, Greece. *Remote Sensing*. 18 janvier 2020. Vol. 12, n° 2, pp. 319. DOI 10.3390/rs12020319.

POTTIER, Nathalie, PENNING-ROWSELL, Edmund, TUNSTALL, Sylvia et HUBERT, Gilles, 2005. Land use and flood protection: contrasting approaches and outcomes in France and in England and Wales. *Applied Geography*. janvier 2005. Vol. 25, n° 1, pp. 1-27. DOI 10.1016/j.apgeog.2004.11.003.

PREETHA, Pooja P., SHIRANI-BIDABADI, Niloufar, AL-HAMDAN, Ashraf Z. et ANDERSON, Michael, 2021. A Methodical Assessment of Floodplains in Mixed Land Covers Encompassing Bridges in Alabama State: Implications of Spatial Land Cover Characteristics on Flood Vulnerability. *Water Resources Management*. mars 2021. Vol. 35, n° 5, pp. 1603-1618. DOI 10.1007/s11269-021-02805-7.

PSOMIADIS, Emmanouil, TOMANIS, Lefteris, KAVVADIAS, Antonis, SOULIS, Konstantinos X., CHARIZOPOULOS, Nikos et MICHAS, Spyros, 2021. Potential Dam Breach Analysis and Flood Wave Risk Assessment Using HEC-RAS and Remote Sensing Data: A Multicriteria Approach. *Water*. 31 janvier 2021. Vol. 13, n° 3, pp. 364. DOI 10.3390/w13030364.

PU, Ruiliang, LANDRY, Shawn, et YU, Qiuyan. Assessing the potential of multi-seasonal high resolution Pléiades satellite imagery for mapping urban tree species. *International Journal of Applied Earth Observation and Geoinformation*, 2018, vol. 71, p. 144-158.

PUECH, Christian, BAILLY, Jean Stéphane, et ENGREF, UMR3S Cemagref. Risques d'inondation et modélisation hydrologique: pièges de l'assimilation de paramètres issus de données spatiales. In : Actes de colloque, SIRNAT. 2003.

PUTRI, Latifa Melani et WICAKSONO, Pramaditya, 2021. MAPPING OF LAND USE CHANGES IN THE CORE ZONE OF PARANGTRITIS SAND DUNES USING OBIA METHOD 2015-2020. *JURNAL GEOGRAFI*. 15 février 2021. Vol. 13, n° 1, pp. 109. DOI 10.24114/jg.v13i1.21465.

RACLOT, D., 2006. Remote sensing of water levels on floodplains: a spatial approach guided by hydraulic functioning. *International Journal of Remote Sensing*. juin 2006. Vol. 27, n° 12, pp. 2553-2574. DOI 10.1080/01431160600554397.

Rao A.R., Hamed K.H. (2001). Flood frequency analysis. CRC Press, New York.

REGHEZZA, Magali, 2007. Réflexions autour de la vulnérabilité métropolitaine: la métropole parisienne face au risque de crue centennale. . pp. 385.

RICARD, Didier, DUCROCQ, Véronique, et AUGER, Ludovic. A climatology of the mesoscale environment associated with heavily precipitating events over a northwestern

Mediterranean area. *Journal of applied meteorology and climatology*, 2012, vol. 51, no 3, p. 468-488.

RIVAS-TABARES, David, TARQUIS, Ana M., DE MIGUEL, Ángel, GOBIN, Anne et WILLAARTS, Bárbara, 2022. Enhancing LULC scenarios impact assessment in hydrological dynamics using participatory mapping protocols in semiarid regions. *Science of The Total Environment*. janvier 2022. Vol. 803, pp. 149906. DOI 10.1016/j.scitotenv.2021.149906.

ROGAN, John, FRANKLIN, Janet, STOW, Doug, MILLER, Jennifer, WOODCOCK, Curtis et ROBERTS, Dar, 2008. Mapping land-cover modifications over large areas: A comparison of machine learning algorithms. *Remote Sensing of Environment*. mai 2008. Vol. 112, n° 5, pp. 2272-2283. DOI 10.1016/j.rse.2007.10.004.

ROUSE, J. W. et al. Monitoring the vernal advancements and retrogradation (greenwave effect) of natural vegetation. NASA/GSFC, Type III, Final Report, Greenbelt. MD., p.1-371, 1974.

Rumiano, Florent. L'utilisation combinée de la télédétection et de la modélisation spatiale pour la mobilité animale : application à l'étude des contacts entre espèces animales sauvages et domestiquées afin d'appréhender le risque de transmission de pathogènes en Afrique Australe. Montpellier : 2021. Université de Montpellier : thèse de doctorat, Ecologie fonctionnelle.

SARHADI, Ali, SOLTANI, Saeed et MODARRES, Reza, 2012. Probabilistic flood inundation mapping of ungauged rivers: Linking GIS techniques and frequency analysis. *Journal of Hydrology*. août 2012. Vol. 458-459, pp. 68-86. DOI 10.1016/j.jhydrol.2012.06.039.

SAKSENA, Siddharth et MERWADE, Venkatesh. Incorporating the effect of DEM resolution and accuracy for improved flood inundation mapping. *Journal of Hydrology*, 2015, vol. 530, p. 180-194.

SEFRIN, Oliver, RIESE, Felix M. et KELLER, Sina, 2020. Deep Learning for Land Cover Change Detection. *Remote Sensing*. 28 décembre 2020. Vol. 13, n° 1, pp. 78. DOI 10.3390/rs13010078.

SEGARRA, Joel, BUCHAILLOT, Maria Luisa, ARAUS, Jose Luis, et al. Remote sensing for precision agriculture: Sentinel-2 improved features and applications. *Agronomy*, 2020, vol. 10, no 5, p. 641.

Sayers, P. B. et alii, Risk, Performance and Uncertainty in Flood and Coastal Defence. A Review. 2002, R&D Technical Report FD2302/TR1 (HR Wallingford Report SR587), Crown Copyright, Londres.

SCHULZ, Dario, YIN, He, TISCHBEIN, Bernhard, VERLEYS DONK, Sarah, ADAMOU, Rabani et KUMAR, Navneet, 2021. Land use mapping using Sentinel-1 and Sentinel-2 time series in a heterogeneous landscape in Niger, Sahel. *ISPRS Journal of Photogrammetry and Remote Sensing*. août 2021. Vol. 178, pp. 97-111. DOI 10.1016/j.isprs.2021.06.005.

SCHULZE, Roland E, 2022. Modelling Hydrological Responses to Land Use and Climate Change: A Southern African Perspective. *South Africa*. 2022. pp. 12.

SCHUMANN, Guy, BATES, Paul D., HORRITT, Matthew S., MATGEN, Patrick et PAPPENBERGER, Florian, 2009. Progress in integration of remote sensing-derived flood

extent and stage data and hydraulic models. *Reviews of Geophysics*. 12 novembre 2009. Vol. 47, n° 4, pp. RG4001. DOI 10.1029/2008RG000274.

SCHUMANN, Guy, HOSTACHE, Renaud, PUECH, Christian, HOFFMANN, Lucien, MATGEN, Patrick, PAPPENBERGER, Florian et PFISTER, Laurent, 2007. High-Resolution 3-D Flood Information From Radar Imagery for Flood Hazard Management. *IEEE Transactions on Geoscience and Remote Sensing*. juin 2007. Vol. 45, n° 6, pp. 1715-1725. DOI 10.1109/TGRS.2006.888103.

SEFRIN, Oliver, RIESE, Felix M. et KELLER, Sina, 2020. Deep Learning for Land Cover Change Detection. *Remote Sensing*. 28 décembre 2020. Vol. 13, n° 1, pp. 78. DOI 10.3390/rs13010078.

SHETTY, Shobitha, GUPTA, Prasun Kumar, BELGIU, Mariana et SRIVASTAV, S. K., 2021. Assessing the Effect of Training Sampling Design on the Performance of Machine Learning Classifiers for Land Cover Mapping Using Multi-Temporal Remote Sensing Data and Google Earth Engine. *Remote Sensing*. 8 avril 2021. Vol. 13, n° 8, pp. 1433. DOI 10.3390/rs13081433.

SHEYKHMUSA, Mohammadreza, MAHDIANPARI, Masoud, GHANBARI, Hamid, MOHAMMADIMANESH, Fariba, GHAMISI, Pedram et HOMAYOUNI, Saeid, 2020. Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2020. Vol. 13, pp. 6308-6325. DOI 10.1109/JSTARS.2020.3026724.

SHI, Dee et YANG, Xiaojun, 2012. Support Vector Machines for Landscape Mapping from Remote Sensor Imagery. . 2012. pp. 12.

Singh, A., 1989. Digital change detection techniques using remotely sensed data, *International Journal of Remote Sensing*, 10:989-1003.

SINHA, Priyakant et KUMAR, Lalit, 2013. Markov Land Cover Change Modeling Using Pairs of Time-Series Satellite Images. *Photogrammetric Engineering & Remote Sensing*. 1 novembre 2013. Vol. 79, n° 11, pp. 1037-1051. DOI 10.14358/PERS.79.11.1037.

SMITH, G P, DAVEY, E K et COX, R, [sans date]. WRL Technical Report 2014/07. . pp. 59.

SMITS, P. C., DELLEPIANE, S. G. et SCHOWENGERDT, R. A., 1999. Quality assessment of image classification algorithms for land-cover mapping: A review and a proposal for a cost-based approach. *International Journal of Remote Sensing*. janvier 1999. Vol. 20, n° 8, pp. 1461-1486. DOI 10.1080/014311699212560.

SOLIN, L. et SKUBINCAN, P. Flood risk assessment and management: review of concepts, definitions and methods. *Geographical Journal*, 2013, vol. 65, no 1, p. 23-44.

SOLÍN, Ľ., SLÁDEKOVÁ MADAJOVÁ, M. et MICHALEJE, L., 2018. Vulnerability assessment of households and its possible reflection in flood risk management: The case of the upper Myjava basin, Slovakia. *International Journal of Disaster Risk Reduction*. juin 2018. Vol. 28, pp. 640-652. DOI 10.1016/j.ijdrr.2018.01.015.

STEFANSKI, Jan, KUEMMERLE, Tobias, CHASKOVSKYY, Oleh, GRIFFITHS, Patrick, HAVRYLUK, Vassiliy, KNORN, Jan, KOROL, Nikolas, SIEBER, Anika et WASKE, Björn,

2014. Mapping Land Management Regimes in Western Ukraine Using Optical and SAR Data. *Remote Sensing*. 6 juin 2014. Vol. 6, n° 6, pp. 5279-5305. DOI 10.3390/rs6065279.

SCHWARTZ G. (1978). Estimating the dimension of a model. *The Annals of Statistics* 6: 461–464.

SUGIANTO, Sugianto, DELI, Anwar, MISWAR, Edy, *et al.* The Effect of Land Use and Land Cover Changes on Flood Occurrence in Teunom Watershed, Aceh Jaya. *Land*, 2022, vol. 11, no 8, p. 1271.

TACHIKAWA, Tetsushi, KAKU, Manabu, IWASAKI, Akira, *et al.* ASTER global digital elevation model version 2–Summary of validation results August 31, 2011. Pasadena, California: Jet Propulsion Laboratory, 2011.

TACNET, J.M et BURNET, R., 2007. Risques naturels Organisation de la gestion et de la prévention en France : Eléments pour une comparaison transfrontalière Version 1.3 [en ligne]. PRINAT-Action n°2-Panorama de l'organisation de la gestion des risques naturels en France, 55 p. [réf. du 26 août 2013].

TANG, Zixia, LI, Mengmeng *et* WANG, Xiaoqin, 2020. Mapping Tea Plantations from VHR Images Using OBIA and Convolutional Neural Networks. *Remote Sensing*. 10 septembre 2020. Vol. 12, n° 18, pp. 2935. DOI 10.3390/rs12182935.

TAMIRU, Habtamu *et* DINKA, Megersa O., 2021. Application of ANN and HEC-RAS model for flood inundation mapping in lower Baro Akobo River Basin, Ethiopia. *Journal of Hydrology: Regional Studies*. août 2021. Vol. 36, pp. 100855. DOI 10.1016/j.ejrh.2021.100855.

TAREKEGN, Tesfaye Haimanot, HAILE, Alemseged Tamiru, RIENTJES, Tom, *et al.* Assessment of an ASTER-generated DEM for 2D hydrodynamic flood modeling. *International Journal of Applied Earth Observation and Geoinformation*, 2010, vol. 12, no 6, p. 457-465.

TARTAKOVSKY, Daniel M. Assessment and management of risk in subsurface hydrology: A review and perspective. *Advances in Water Resources*, 2013, vol. 51, p. 247-260.

TAVARES, Paulo, BELTRÃO, Norma, GUIMARÃES, Ulisses *et* TEODORO, Ana, 2019. Integration of Sentinel-1 and Sentinel-2 for Classification and LULC Mapping in the Urban Area of Belém, Eastern Brazilian Amazon. *Sensors*. 6 mars 2019. Vol. 19, n° 5, pp. 1140. DOI 10.3390/s19051140.

TEHRANY, Mahyat Shafapour, PRADHAN, Biswajeet *et* JEBUV, Mustafa Neamah, 2014. A comparative assessment between object and pixel-based classification approaches for land use/land cover mapping using SPOT 5 imagery. *Geocarto International*. 19 mai 2014. Vol. 29, n° 4, pp. 351-369. DOI 10.1080/10106049.2013.768300.

TIAN, Haifeng, CHEN, Ting, LI, Qiangzi, *et al.* A Novel Spectral Index for Automatic Canola Mapping by Using Sentinel-2 Imagery. *Remote Sensing*, 2022, vol. 14, no 5, p. 1113.

TIMILSINA, S., SHARMA, S. K. *et* ARYAL, J., 2019. MAPPING URBAN TREES WITHIN CADASTRAL PARCELS USING AN OBJECT-BASED CONVOLUTIONAL NEURAL NETWORK. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information*

Sciences. 5 décembre 2019. Vol. IV-5/W2, pp. 111-117. DOI 10.5194/isprs-annals-IV-5-W2-111-2019.

THANH NOI, Phan et KAPPAS, Martin, 2017. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. *Sensors*. 22 décembre 2017. Vol. 18, n° 2, pp. 18. DOI 10.3390/s18010018.

Tong, Xiaohua, Huan Xie, ET Qihao Weng. (2014). Urban Land Cover Classification with Airborne Hyperspectral Data: What Features to Use? *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7 (10): 3998-4009. <https://doi.org/10.1109/JSTARS.2013.2272212>.

TRAMBLAY Y., ST-HILAIRE A., OUARDA T. (2008). Frequency analysis of maximum annual suspended sediment concentrations in North America. *Hydrological Sciences Journal* 1: 236- 252.

TUIA, Devis, VOLPI, Michele, COPA, Loris, KANEVSKI, Mikhail et MUNOZ-MARI, Jordi, 2011. A Survey of Active Learning Algorithms for Supervised Remote Sensing Image Classification. *IEEE Journal of Selected Topics in Signal Processing*. juin 2011. Vol. 5, n° 3, pp. 606-617. DOI 10.1109/JSTSP.2011.2139193.

UNAVO, <https://www.unavco.org/highlights/2018/2018.html> .

USACE. 2016. HEC-RAS River Analysis System - Hydraulic Reference Manual, Version 5.0. Hydrologic Engineering Centre (HEC), U. S. Army Corps of Engineers DOI: CPD-68

USTIN, Susan L., GITELSON, Anatoly A., JACQUEMOUD, Stéphane, et al. Retrieval of foliar information about plant pigment systems from high resolution spectroscopy. *Remote Sensing of Environment*, 2009, vol. 113, p. S67-S77.

VAGLIO LAURIN, Gaia, LIESENBERG, Veraldo, CHEN, Qi, GUERRIERO, Leila, DEL FRATE, Fabio, BARTOLINI, Antonio, COOMES, David, WILEBORE, Beccy, LINDSELL, Jeremy et VALENTINI, Riccardo, 2013. Optical and SAR sensor synergies for forest and land cover mapping in a tropical site in West Africa. *International Journal of Applied Earth Observation and Geoinformation*. avril 2013. Vol. 21, pp. 7-16. DOI 10.1016/j.jag.2012.08.002.

VAN DER SANDE, C.J., DE JONG, S.M. et DE ROO, A.P.J., 2003. A segmentation and classification approach of IKONOS-2 imagery for land cover mapping to assist flood risk and flood damage assessment. *International Journal of Applied Earth Observation and Geoinformation*. juin 2003. Vol. 4, n° 3, pp. 217-229. DOI 10.1016/S0303-2434(03)00003-5.

VAN TRICHT, Kristof, GOBIN, Anne, GILLIAMS, Sven et PICCARD, Isabelle, 2018. Synergistic Use of Radar Sentinel-1 and Optical Sentinel-2 Imagery for Crop Mapping: A Case Study for Belgium. *Remote Sensing*. 16 octobre 2018. Vol. 10, n° 10, pp. 1642. DOI 10.3390/rs10101642.

VARADE, Divyesh M., MAURYA, Ajay K. et DIKSHIT, Onkar, 2019. Development of Spectral Indexes in Hyperspectral Imagery for Land Cover Assessment. *IETE Technical Review*. 3 septembre 2019. Vol. 36, n° 5, pp. 475-483. DOI 10.1080/02564602.2018.1503569.

VELDKAMP, A et LAMBIN, E.F, 2001. Predicting land-use change. *Agriculture, Ecosystems & Environment*. juin 2001. Vol. 85, n° 1-3, pp. 1-6. DOI 10.1016/S0167-8809(01)00199-2.

VEMPALA, S., 1997. A random sampling based algorithm for learning the intersection of half-spaces. In : *Proceedings 38th Annual Symposium on Foundations of Computer Science* [en ligne]. Miami Beach, FL, USA : IEEE Comput. Soc. 1997. pp. 508-513. [Consulté le 19 août 2022]. ISBN 978-0-8186-8197-4. Disponible à l'adresse : <http://ieeexplore.ieee.org/document/646139/>

VERLYNDE, Nicolas ., 2018. De la perception du risque d'inondation aux propositions d'adaptation en territoire de côtes basses densément peuplées: le cas de la communauté urbaine de Dunkerque. . pp. 617.

WAGNER, Wolfgang, SABEL, Daniel, DOUBKOVA, Marcela, et al. Prospects of Sentinel-1 for land applications. In : 2012 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2012. p. 1741-1744.

WALD, Abraham et WOLFOWITZ, Jacob. An exact test for randomness in the non-parametric case based on serial correlation. *The Annals of Mathematical Statistics*, 1943, vol. 14, no 4, p. 378-388.

WALD, L., 1999. Some terms of reference in data fusion. *IEEE Transactions on Geoscience and Remote Sensing*. mai 1999. Vol. 37, n° 3, pp. 1190-1193. DOI 10.1109/36.763269.

WANG, Le, SHI, Chen, DIAO, Chunyuan, JI, Wenjie et YIN, Dameng, 2016. A survey of methods incorporating spatial information in image classification and spectral unmixing. *International Journal of Remote Sensing*. 17 août 2016. Vol. 37, n° 16, pp. 3870-3910. DOI 10.1080/01431161.2016.1204032.

WANG, Lei, CHEN, Yang, TANG, Luliang, et al. Object-based convolutional neural networks for cloud and snow detection in high-resolution multispectral imagers. *Water*, 2018, vol. 10, no 11, p. 1666.

WANG, Sonam Wangyel, GEBRU, Belay Manjur, LAMCHIN, Munkhnasan, KAYASTHA, Rijan Bhakta et LEE, Woo-Kyun, 2020. Land Use and Land Cover Change Detection and Prediction in the Kathmandu District of Nepal Using Remote Sensing and GIS. *Sustainability*. 11 mai 2020. Vol. 12, n° 9, pp. 3925. DOI 10.3390/su12093925.

WANG, Wensheng et DING, Jing. Wavelet network model and its application to the prediction of hydrology. *Nature and Science*, 2003, vol. 1, no 1, p. 67-71.

WASKE, B. et BENEDIKTSSON, J.A., 2007. Fusion of Support Vector Machines for Classification of Multisensor Data. *IEEE Transactions on Geoscience and Remote Sensing*. décembre 2007. Vol. 45, n° 12, pp. 3858-3866. DOI 10.1109/TGRS.2007.898446.

WENG, Qihao, 2002. Land use change analysis in the Zhujiang Delta of China using satellite remote sensing, GIS and stochastic modelling. *Journal of Environmental Management*. mars 2002. Vol. 64, n° 3, pp. 273-284. DOI 10.1006/jema.2001.0509.

WERNER, M.G.F., HUNTER, N.M. et BATES, P.D., 2005. Identifiability of distributed floodplain roughness values in flood extent estimation. *Journal of Hydrology*. novembre 2005. Vol. 314, n° 1-4, pp. 139-157. DOI 10.1016/j.jhydrol.2005.03.012.

- WERNER, M. G. F., HUNTER, N. M., et BATES, P. D. Identifiability of distributed floodplain roughness values in flood extent estimation. *Journal of Hydrology*, 2005, vol. 314, no 1-4, p. 139-157.
- WHITE, Joanne C., WULDER, M. A., HOBART, G. W., et al. Pixel-based image compositing for large-area dense time series applications and science. *Canadian Journal of Remote Sensing*, 2014, vol. 40, no 3, p. 192-212.
- WHYTE, Andrew, FERENTINOS, Konstantinos P. et PETROPOULOS, George P., 2018. A new synergistic approach for monitoring wetlands using Sentinels -1 and 2 data with object-based machine learning algorithms. *Environmental Modelling & Software*. juin 2018. Vol. 104, pp. 40-54. DOI 10.1016/j.envsoft.2018.01.023.
- WIDASMARA, Mega Yulisetya, HADI, Pramono, et CHRISTANTO, Nugroho. Hydrograph modeling with rational modified method. In : E3S Web of Conferences. EDP Sciences, 2019. p. 02007.
- XIAO, Shuyuan, WANG, Tao, LIU, Tingting, et al. Active metamaterials and metadevices: a review. *Journal of Physics D: Applied Physics*, 2020, vol. 53, no 50, p. 503002.
- XIE, Guanyao et NICULESCU, Simona, 2021. Mapping and Monitoring of Land Cover/Land Use (LCLU) Changes in the Crozon Peninsula (Brittany, France) from 2007 to 2018 by Machine Learning Algorithms (Support Vector Machine, Random Forest, and Convolutional Neural Network) and by Post-classification Comparison (PCC). *Remote Sensing*. 29 septembre 2021. Vol. 13, n° 19, pp. 3899. DOI 10.3390/rs13193899.
- YALCIN, Emrah, 2020. Assessing the impact of topography and land cover data resolutions on two-dimensional HEC-RAS hydrodynamic model simulations for urban flood hazard analysis. *Natural Hazards*. avril 2020. Vol. 101, n° 3, pp. 995-1017. DOI 10.1007/s11069-020-03906-z.
- YALEW, S.G., PILZ, T., SCHWEITZER, C., LIERSCH, S., VAN DER KWAST, J., VAN GRIENSVEN, A., MUL, M.L., DICKENS, C. et VAN DER ZAAG, P., 2018. Coupling land-use change and hydrologic models for quantification of catchment ecosystem services. *Environmental Modelling & Software*. novembre 2018. Vol. 109, pp. 315-328. DOI 10.1016/j.envsoft.2018.08.029.
- YANG, Jun, GONG, Peng, FU, Rong, et al. The role of satellite remote sensing in climate change studies. *Nature climate change*, 2013, vol. 3, no 10, p. 875-883.
- YE, Yunming, WU, Qingyao, ZHEXUE HUANG, Joshua, NG, Michael K. et LI, Xutao, 2013. Stratified sampling for feature subspace selection in random forests for high dimensional data. *Pattern Recognition*. mars 2013. Vol. 46, n° 3, pp. 769-787. DOI 10.1016/j.patcog.2012.09.005.
- YIN, Dingkun, EVANS, Barry, WANG, Qi, et al. Integrated 1D and 2D model for better assessing runoff quantity control of low impact development facilities on community scale. *Science of the Total Environment*, 2020, vol. 720, p. 137630.
- YIN, Shoulin, ZHANG, Ye et KARIM, Shahid, 2018. Large Scale Remote Sensing Image Segmentation Based on Fuzzy Region Competition and Gaussian Mixture Model. *IEEE Access*. 2018. Vol. 6, pp. 26069-26080. DOI 10.1109/ACCESS.2018.2834960.

YIN, Jing, HE, Fan, XIONG, Yu Jiu et QIU, Guo Yu, 2017. Effects of land use/land cover and climate changes on surface runoff in a semi-humid and semi-arid transition zone in northwest China. *Hydrology and Earth System Sciences*. 10 janvier 2017. Vol. 21, n° 1, pp. 183-196. DOI 10.5194/hess-21-183-2017.

ZAABAR, N., NICULESCU, S. et MIHOUBI, M. K., 2021. ASSESSMENT OF COMBINING CONVOLUTIONAL NEURAL NETWORKS AND OBJECT BASED IMAGE ANALYSIS TO LAND COVER CLASSIFICATION USING SENTINEL 2 SATELLITE IMAGERY (TENES REGION, ALGERIA). *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 28 juin 2021. Vol. XLIII-B3-2021, pp. 383-389. DOI 10.5194/isprs-archives-XLIII-B3-2021-383-2021.

ZAABAR, Narimane, NICULESCU, Simona, et MIHOUBI, Mustapha Kamel, 2022. Application of convolutional neural networks with object-based image analysis for land cover and land use mapping in coastal areas: A case study in Ain Témouchent, Algeria. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2022. pp. 1-16. DOI 10.1109/JSTARS.2022.3185185.

ZAABAR, Narimane, NICULESCU, Simona et MIHOUBI, Mustapha Kamel, 2022. Application of convolutional neural networks with object-based image analysis for land cover and land use mapping in coastal areas: A case study in Ain Témouchent, Algeria. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2022. pp. 1-16. DOI 10.1109/JSTARS.2022.3185185.

ZAABAR, Narimane, NICULESCU, Simona et MIHOUBI, Mustapha Kamel, 2022. Assessment of Land Cover Changes in the Allala Watershed Based on Object Based Image Analysis Using Landsat and Sentinel-2 Images. In: Niculescu, S. (eds) *European Spatial Data for Coastal and Marine Remote Sensing*. Springer, Cham. https://doi.org/10.1007/978-3-031-16213-8_5.

ZHA, Y., GAO, J. et NI, S., 2003. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*. janvier 2003. Vol. 24, n° 3, pp. 583-594. DOI 10.1080/01431160304987.

ZHANG, Ce, SARGENT, Isabel, PAN, Xin, LI, Huapeng, GARDINER, Andy, HARE, Jonathon et ATKINSON, Peter M., 2018. An object-based convolutional neural network (OCNN) for urban land use classification. *Remote Sensing of Environment*. octobre 2018. Vol. 216, pp. 57-70. DOI 10.1016/j.rse.2018.06.034.

ZHANG, Keqi, GANN, Daniel, ROSS, Michael, et al. *Accuracy assessment of ASTER, SRTM, ALOS, and TDX DEMs for Hispaniola and implications for mapping vulnerability to coastal flooding. Remote Sensing of Environment, 2019, vol. 225, p. 290-306.*

ZHANG, Ke, SHALEHY, Md Halim, EZAZ, Gazi Tawfiq, CHAKRABORTY, Arup, MOHIB, Kazi Mushfique et LIU, Linxin, 2022. An integrated flood risk assessment approach based on coupled hydrological-hydraulic modeling and bottom-up hazard vulnerability analysis. *Environmental Modelling & Software*. février 2022. Vol. 148, pp. 105279. DOI 10.1016/j.envsoft.2021.105279.

ZHAO, Wenzhi, DU, Shihong et EMERY, William J., 2017. Object-Based Convolutional Neural Network for High-Resolution Imagery Classification. *IEEE Journal of Selected Topics*

in Applied Earth Observations and Remote Sensing. juillet 2017. Vol. 10, n° 7, pp. 3386-3396. DOI 10.1109/JSTARS.2017.2680324.

ZHOU, Chao, CAO, Ying, YIN, Kunlong, et al. Landslide characterization applying sentinel-1 images and InSAR technique: The muyubao landslide in the three Gorges Reservoir Area, China. *Remote Sensing*, 2020, vol. 12, no 20, p. 3385.

ZOPE, P.E., ELDHO, T.I. et JOTHIPRAKASH, V., 2016. Impacts of land use–land cover change and urbanization on flooding: A case study of Oshiwara River Basin in Mumbai, India. *CATENA*. octobre 2016. Vol. 145, pp. 142-154. DOI 10.1016/j.catena.2016.06.009.

ZOPE, P. E., ELDHO, T. I. et JOTHIPRAKASH, V., 2017. Hydrological impacts of land use–land cover change and detention basins on urban flood hazard: a case study of Poisar River basin, Mumbai, India. *Natural Hazards*. juillet 2017. Vol. 87, n° 3, pp. 1267-1283. DOI 10.1007/s11069-017-2816-4.



Titre : Synergie des données satellitaires optique et radar pour l'étude des zones côtières inondables à l'ouest algérien

Mots clés : Risque d'inondation, zone inondable, occupation du sol, Machine et Deep Learning, modèle hydraulique, Modèle Numérique de Surface.

Résumé : L'évaluation du risque d'inondation et la planification de l'occupation du sol des zones inondables sont devenues des actions essentielles dans le cadre de la stratégie de lutte contre les inondations. Ce contexte explique la conception d'une nouvelle méthode d'analyse des zones inondables, celle qui intègre les images satellites aux modèles hydrauliques. La méthode proposée a été appliquée sur deux zones côtières inondables à l'Ouest algérien. En premier temps, des méthodes de Machine et Deep Learning ont été appliquées pour la classification de l'occupation du sol de ces zones. Les classifications ont été réalisées à l'aide de plusieurs images satellitaires à haute et très haute résolution spatiale avec deux niveaux de l'image : pixel et objet. Les résultats fiables de la modélisation de l'occupation du sol des zones inondables ont été ensuite intégrés à un modèle hydraulique.

A ce niveau , un Modèle Numérique de Surface (MNS) provenant d'une image Pléiades à très haute résolution spatiale a été utilisé en amont du modèle comme donnée topographique. Les résultats de simulation d'aléa inondation et d'évaluation du risque d'inondation montrent que les zones susceptibles d'être inondées sont principalement situées près de la rivière, et s'étendent vers la plaine inondable du bassin versant étudié (mets le nom de la rivière et du bassin versant). Ces zones sont caractérisées par la présence d'infrastructures et des constructions en raison de l'expansion de la tâche urbaine. La concentration urbaine rend ces zones très vulnérables aux inondations. Les résultats de la de la synergie méthodologique et de différents types de données spatiales pourront être un outil fiable d'aide à la décision, notamment pour le renforcement du plan d'aménagement et l'élaboration des plans de prévention du risque d'inondation (PPRI).

Title : Synergy of optical and radar satellite data for the study of coastal flood-prone areas in western Algeria

Keywords : Flood risk, flood prone-area, land cover, Machine and Deep Learning, hydraulic model, Digital Surface Model.

Abstract : Flood risk assessment and land cover planning of flood-prone areas have become key actions in the framework of flood control strategy. This will has motivated the design of a new method of analysis of flood-prone areas that integrates the contribution of remote sensing with hydraulic models. The proposed method has been applied on two coastal floodable areas in Western Algeria. First, Machine and Deep Learning methods are applied for the land cover classification in these areas. This classification was performed on multiple high and very high spatial resolution satellite images at two image levels: pixel and object. The results of the accurate modeling of the land use of flood-prone areas were then integrated into a hydraulic model.

Here, a Digital Surface Model (DSM) from a Pleiades image with very high spatial resolution was used upstream of the model as topographic data. The results of the flood hazard simulation and flood risk assessment show that the areas susceptible to flooding are mainly located near the river, and extend towards the floodplain of the studied watershed. These areas are characterized by the presence of infrastructures and constructions due to the expansion of the urban extension. This urban concentration makes these areas very vulnerable to flooding. The results of the applied method could be a reliable tool for decision support, especially for the reinforcement of the development plan and the elaboration of the flood risk prevention plans (PPRI).