

THÈSE

En Vue de l'obtention du : **DOCTORAT**

Centre de Recherche : GEOPAC

Structure de recherche : GEOBIO

Discipline : Géoscience

Spécialité : Observation de la Terre - Géomatique

Présentée par :

Sofia HAKDAOUI

Monitoring et Détection de Changement par Intelligence Artificielle.

Applications aux Provinces Sud du Maroc et au Pont à Haubans

Mohammed VI de Rabat

Abdessamad ADRAOUI	EL	PES, Faculté des Sciences Rabat. Université Mohammed V	Président
Anas EMRAN		PES, Institut Scientifique de Rabat Université Mohammed V	Directeur de Thèse
Ilias KACIMI		PES, Faculté des Sciences Rabat. Université Mohammed V.	Rapporteur / Examineur
Ahmed EL ABOUDI		PES, Faculté des Sciences Rabat Université Mohammed V	Rapporteur/ Examineur
Loubna EL MANSOURI		PH, I.A.V. Hassan II, Rabat, Maroc.	Rapporteur/ Examineur
Hassan AMMOR		PES, École Mohammadia d'Ingénieurs, Université Mohammed V, Rabat.	Examineur
Khalid MINAOUI		PH, Université Mohammed V, FS Rabat, Maroc	Examineur
Laurent POLIDORI		Directeur de recherches au CNRS - Directeur du Centre d'Etudes Spatiales et de la BIOSphère – UMR 5126 (UPS-CNRS-CNES-IRD), Toulouse, France.	Examineur
Abderrahmane TOUZANI		PES, École Mohammadia d'Ingénieurs, Université Mohammed V, Rabat, Maroc.	Invité

Année Universitaire : 2019-2020

Faculté des Sciences, avenue Ibn Battouta, BP, 1014 RP, Rabat – Maroc

Tel : 00212 (05) 37 77 18 76 fax : 00212 (05) 37 77 42 61 ; <http://www.fsr.um5.ac.ma>

Dédicaces

A mes très chers parents, Vous avez comblés ma vie de tendresse d'affection et de compréhension rien au monde ne pourrait compenser les efforts et les sacrifices que vous avez consentis pour mon bien être, et la poursuite de mes études dans de bonnes conditions. Aucune dédicace ne serait exprimée à sa juste valeur le profond amour que je vous porte Puisse dieu, vous procure santé, bonheur et longue vie.

A mon frère Hamza, pour son soutien moral, son encouragement et son grand amour qui m'a permis de surmonter toutes les difficultés, Je t'aime beaucoup.

A tous mes professeurs.

A tous mes amis,

A tous ceux qui me sont chers,

pour leur soutien et leur encouragement, pour les inoubliables moments que nous avons vécus ensemble. Merci d'être là et merci pour tous ce que vous avez fait pour moi.

Sofia HAKDAOUI

Remerciements

*Je tiens à remercier dans un premier temps, toute l'équipe pédagogique de l'institut Scientifique de Rabat, les responsables, les professeurs et membres de notre centre de recherche Geophysics, Natural Patrimony and Green Chemistry (GEOPAC), sous la direction du **Pr. Abdelfatah TAHIRI**.*

*Je tiens à remercier la structure de recherche du laboratoire Géo-Biodiversité et Patrimoine Naturel (GEOBIO) de l'Institut Scientifique de Rabat dans lequel ce travail de recherche a été effectué sous la direction de **Pr. Abdelfatah TAHIRI**.*

*Je voudrais exprimer toute ma reconnaissance à mon directeur de thèse **Pr. Anas EMRAN**, Professeur à l'institut Scientifique de Rabat pour sa générosité, sa disponibilité permanente, sa rigueur scientifique, ses conseils. Il m'a appris à être plus autonome dans ce travail de recherche.*

*Je tiens aussi à exprimer mes sincères remerciements à tous les membres de jury a **Pr. Abdessamad EL ADRAOUI**, Professeur à la faculté des Sciences de Rabat d'avoir pris la charge de présider le jury un grand merci pour sa présence ainsi que ses précieux conseils.*

*J'exprime ma gratitude aussi au **Pr. Loubna EL MANSOURI**, Professeur à l'institut agronomique et vétérinaire Hassan II pour son aide, ses orientations et ses conseils. D'avoir accepté d'être rapporteur de cette thèse, c'est en travaillant à ses côtés que j'ai compris ce que précision et travail méticuleux voulaient dire.*

*Je tiens à remercier **Pr. Ilias KACIMI** Professeur à la Faculté des Sciences de Rabat un grand merci pour ses précieuses remarques et son soutien et pour le temps accordé en acceptant d'être rapporteur de cette thèse.*

*Mes remerciements s'adressent aussi au **Professeur Ahmed EL ABOUDI**, Professeur à la Faculté des Sciences de Rabat d'avoir accepté d'être rapporteur de ce travail, mes sincères remerciements pour ses précieux conseils.*

*Mes vifs remerciements au **Pr. Hassan AMMOR**, professeur à l'École Mohammadia d'Ingénieurs d'avoir accepté d'examiner ce travail, un grand merci pour son aide précieuse et ses conseils constructifs qui m'ont énormément aidé et permis de me perfectionner.*

*Je tiens à remercier **Pr. Khalid MINAOUI**, Professeur à la Faculté des Sciences de Rabat en sa qualité d'examinateur mes vifs remerciements pour ses précieux conseils.*

*Je tiens à remercier vivement **Pr. Laurent POLIDORI**, Directeur de recherches au CNRS et Directeur du Centre d'Études Spatiales et de la BIOSphère de Toulouse, d'avoir accepté d'évaluer mon travail un grand merci sa disponibilité, pour l'effort fourni ainsi que pour les précieux conseils apportés.*

*Je remercie particulièrement **Pr. Abderrahmane TOUZANI**, ex- professeur à l'École Mohammadia d'Ingénieurs et directeur du CRASTE-LF pour son soutien et sa confiance et de m'avoir permis de participer aux activités scientifiques au sein du CRASTE – LF, et de faire l'encadrement des stagiaires, et d'assurer le cours de l'infrastructure spatiale dans le cadre du Master en Sciences et Technologie de l'Espace option Télédétection et Systèmes d'Informations Géographiques (T&SIG) du CRASTE-LF. Merci de m'avoir donné l'occasion d'animer un workshop en Côte d'Ivoire sur le webmapping et le partage des données géospatiales et surtout de m'avoir honoré par sa présence en tant que membre du jury. Un grand merci pour votre encadrement, vos précieux conseils ainsi que votre confiance accordée tout au long de ce parcours.*

*Tous mes remerciements s'adressent au **Pr. Mohamed FEKHAOU**, directeur de l'Institut Scientifique de Rabat, a **Pr. Mohammed LFERDE** du CeDOC de la Faculté des Sciences de Rabat pour leur aide et précieux conseils tout au long du parcours doctoral.*

*Je remercie également **Pr. Biswajeet PRADHAN** et **Pr. Hassane JARRAR OULIDI** pour leur collaboration.*

*Mes chaleureux remerciements vont à l'ensemble des enseignants et des doctorants au sein de l'institut Scientifique, à la faculté des Sciences de Rabat et aux Membres et Professeurs du CRASTE-LF pour leur coopération professionnelle tout au long de la réalisation de cette thèse. À Mr **Faiz OUMGHAR** directeur de Leica Geosystems SARLAU pour son soutien et la mise à disposition des ressources matériels et logiciels des solutions Leica Geosystems.*

Que mes amis, mes proches et tous ceux qui m'ont assisté de près ou de loin veuillent trouver ici mes sincères remerciements.

Résumé

L'Observation de la terre (OT), l'Internet des Objets (IoT), les SIG, le Big Data géospatiale et tout dernièrement la technologie des Jumeaux Numériques (JN) couplés aux algorithmes d'Intelligence Artificielle (IA) apportent une contribution efficace à la protection des écosystèmes naturels fragiles, à la lutte contre les catastrophes naturelles ou à la surveillance et à la maintenance de l'état de santé des infrastructures de la ville. Trois cas d'application des algorithmes d'IA dans des environnements très variés ont été proposés. La première s'est concentrée sur le développement d'une approche collaborative basée sur une analyse spectrale et catégorique pour le suivi et la cartographie des changements de l'étendu de l'eau après des inondations éclair dans une zone humide désertique au Sud du Maroc. Dans le deuxième exemple d'application, nous avons développé un flux de travail géospatial basé sur l'application de l'algorithme d'IA couplé à des traitements d'analyse spectrale en mode distribué (Cloud Computing) sur la plateforme Google Earth Engine (GEE) pour cartographier, surveiller et suivre efficacement les cavités d'eau salée de la Sebkha d'Imlili. Enfin, dans le dernier cas d'application, nous avons proposé une méthodologie basée sur l'utilisation d'algorithmes d'IA appliqués à la donnée LIDAR provenant d'un système de cartographie mobile (M3D) pour le développement d'une interface JN dédiée à la surveillance et à la maintenance du pont à haubans Mohammed VI de Rabat. Ces trois exemples, montrent que les algorithmes d'IA peuvent être appliqués sur des problématiques très variées allant de l'extraction d'informations et la détection des changements sur des images d'OT jusqu'à l'extraction d'objets 3D sur les nuages de points et proposons des flux de travaux pour l'intégration de ces résultats dans des plateformes JN.

Mots clefs : Observation de la Terre, Intelligence Artificielle, Jumeau Numérique, écosystèmes Sahariens, inondation éclair, pont à haubans Mohammed VI.

Abstract

Earth Observation (EO), Internet of Objects (IoT), GIS, Geospatial Big Data and most recently Digital Twin (JN) technology coupled with Artificial Intelligence (AI) algorithms make a contribution effective in protecting fragile natural ecosystems, combating natural disasters or monitoring and maintaining the state of health of the city's infrastructure. Three cases of application of AI algorithms in a wide variety of environments have been proposed. The first focused on the development of a collaborative approach based on a spectral and categorical analysis for monitoring and mapping changes in the extent of water after flash floods in a desert wetland in southern Morocco. In the second application example, we developed a geospatial workflow based on the application of the AI algorithm coupled with spectral analysis processing in distributed mode (Cloud Computing) on the Google Earth Engine platform (GEE) to effectively map, monitor and follow the saltwater cavities of the Sebkha of Imlili. Finally, in the last application case, we proposed a methodology based on the use of AI algorithms applied to LIDAR data coming from a mobile mapping system (M3D) for the development of a JN interface dedicated to the surveillance and maintenance of the Mohammed VI cable-stayed bridge in Rabat. These three examples show that AI algorithms can be applied to a wide variety of issues ranging from information extraction and detection of changes on EO images to the extraction of 3D objects on point clouds and propose workflows for the integration of these results in JN platforms.

Keywords: Earth observation, Artificial Intelligence, Digital Twin, Saharan ecosystems, flash flood, cable-stayed bridge Mohammed VI.

ملخص

إن رصد الأرض (EO)، وإنترنت الأشياء (IoT)، ونظم المعلومات الجغرافية، والبيانات الجغرافية المكانية الأحداث، وتقنية التوائم الرقمي Digital Twin (DT) إلى جانب خوارزميات الذكاء الاصطناعي يمكن أن تقدم مساهمة فعالة في حماية النظم البيئية الطبيعية الهشة، ومكافحة الكوارث الطبيعية أو مراقبة الحالة الجيدة للبنية التحتية للمدينة والحفاظ عليها. من خلال تطوير المنصات الرقمية المتصلة والعمل في الوقت الانلي، يمكننا تحليل التغيرات ورصدها والتنبؤ بها ومحاكاة السيناريوهات والمساعدة في اتخاذ القرار من أجل توقع الحوادث المستقبلية. يُظهر هذا البحث أن تقارب هذه التقنيات مع استخدام خوارزميات الذكاء الاصطناعي لمعالجة هذه البيانات الضخمة في بيئة موزعة سيؤدي إلى أتمتة وتحسين سير العمل الرقمي وتغيير أساليب العمل الحالية. تم اقتراح ثلاثة أمثلة لتطبيق خوارزميات الذكاء الاصطناعي في مجموعة متنوعة من البيانات. ركز الأول على تطوير نهج تعاوني يعتمد على التحليل الطيفي والفئات باستخدام خوارزمية دعم آلة المتجهات لتتبع ورسم التغيرات في حجم المياه بعد الفيضانات المفاجئة في المناطق الرطبة الصحراء في جنوب المغرب. في مثال التطبيق الثاني، قمنا بتطوير سير عمل جغرافي مكاني بناءً على تطبيق خوارزمية الذكاء الاصطناعي العشوائي للغابة (RF) إلى جانب معالجة التحليل الطيفي في الوضع الموزع (الحوسبة السحابية) على نظام Earth Engine Google (GEE) لرسم خريطة ومتابعة تجاوب المياه المالحة لسبخة إمليلي ومتابعتها بكفاءة وسرعة. أخيرًا، في المثال الأخير، اقترحنا سير عمل يعتمد على استخدام خوارزميات الذكاء الاصطناعي لتطوير واجهة رقمية مزدوجة مخصصة لرصد وصيانة جسر محمد السادس المعلق بكابل بالرباط. من خلال هذه الأمثلة الثلاثة، نظهر أنه يمكن تطبيق خوارزميات الذكاء الاصطناعي على مجموعة متنوعة من المشكلات التي تتراوح من استخراج المعلومات واكتشاف التغيرات في صور رصد الأرض إلى اكتشاف كائنات ثلاثية الأبعاد على السحب النقطية ودمج هذه النتائج في منصات التوائم الرقمي. تمثل هذه الدراسة الأولى من نوعها للتأكيد على أهمية هذه التقنية التوائم الرقمي التي يمكن استخدامها في مجموعة متنوعة من المجالات التي تتراوح من تطوير خطط الصمود إلى المخاطر الطبيعية، إلى حماية التراث الطبيعي مروراً بالمراقبة والحفاظ على الحالة السليمة للبنية التحتية الحضرية والطرق.

الكلمات المفتاحية: رصد الأرض، الذكاء الاصطناعي، التوائم الرقمي، النظم البيئية الصحراوية، الفيضانات المفاجئة، جسر محمد السادس.

Sommaire

Dédicaces	iii
Remerciements.....	iv
Résumé.....	vi
Abstract	vii
ملخص	viii
Sommaire	ix
List of Figures	xiii
List of Tables	xvii
Nomenclature.....	19
Introduction générale	23
PARTIE 1 : État de l’art.....	36
Partie1 : Introduction	37
Chapitre 1 : Le Big Data géospatial.....	40
1.1 Introduction	40
1.2 Les particularités du Big Data géospatial.....	41
1.3 Défis de la recherche dans le domaine de la cartographie des Big Data Géospatiales 47	
Chapitre 2 : Les approches d’apprentissage automatiques	49
2.1 Introduction	49
2.2 Les différents types de classification selon l’hypothèse sur la distribution des données images (Paramétrique et non-paramétrique).....	51
2.3 L’approche de classification hybride ou collaborative	54
2.4 Les différents types de classification selon l’approche utilisée : approche Pixel (PBIA), approche Objet (OBIA)) et approche Sub-Pixel (SPBIA)	55
2.5 Les machines à vecteurs de support (Support Vector Machine SVM)	63
2.5.1 Principe des machines à vecteurs de support.....	64
2.5.2 La SVM dans le domaine d’OT	70
2.6 Random Forest (RF).....	73
2.6.1 Arbre de décision (DT)	73
2.6.2 Random Forest (RF)	74
2.7 La faisabilité de l’approche basée sur ML pour le nuage de point	78
2.8 Interprétation ML basée sur le nuage de point.....	79
2.9 La classification du nuage de points	81

ix

2.10	Le Jumeaux Numérique (JN) ou Digital Twin (DT).....	83
2.11	Le JN pour la ville ou City Digital Twins	85
2.12	Intégration SIG-BIM pour les JN de la ville	86
2.13	Conclusion.....	87
Partie 1 : Conclusion.....		89
PARTIE 2 : Étude de Cas		90
Partie 2 : Introduction		91
Chapitre 3 : Approche collaborative de détection des changements sur l'imagerie spatiale multi-capteurs pour la surveillance des zones humides désertiques après une crue éclair dans le sud du Maroc.....		94
3.1	Introduction	94
3.2	Matériel et méthodes	97
3.2.1	Zone d'étude	97
3.2.2	Matériaux	100
3.2.3	Jeu de données et prétraitement	100
3.2.4	Méthodologie	106
3.3	Résultats et discussion.....	122
3.3.1	Cartographie des changements obtenu à partir des données optiques	123
3.3.2	Cartographie des changements obtenue à partir des données SAR	129
3.3.3	Suivi de l'étendue d'eau de la rivière après une crue éclair.....	130
3.3.4	Suivi de l'étendue de l'eau de Sebkhah et de l'humidité du sol après une crue éclair	131
3.3.5	Discussion et proposition d'un flux de travail pour le développement d'un JN pour la résilience aux inondations	132
3.4	Conclusion.....	135
Chapitre 4 : Évaluation des changements dans l'état humide / sec de surface des cavités d'eau de la Sebkhah d'Imlili dans le sud-ouest du Maroc en utilisant la classification d'apprentissage automatique dans Google Earth Engine.....		137
4.1	Introduction	137
4.2	Matériels et méthodes.....	143
4.2.1	Zone d'étude et physiologie générale.....	143
4.2.2	Données d'observation de la Terre.....	144
4.2.3	Données sur l'état du sol mesurées sur le terrain.....	146
4.2.4	DEM, géomorphologie, hydrologie et géologie d'Imlili Sebkhah	147
4.2.5	Données spatiales, prétraitement et extraction des caractéristiques spectrales	149
4.2.6	Fusion de données radar / optique	156
4.2.7	Classification par approche machine learning en utilisant l'algorithme Random Forest (RF) au sein de GEE	157

4.3	Résultats	160
4.3.1	Cartographie des changements des caractéristiques environnementales de la Sebkha d'Imlili à partir de données optiques.....	160
4.3.2	Cartographie des changements des caractéristiques environnementales de la Sebkha d'Imlili à partir des données SAR.....	165
4.3.3	Collaboration SAR / Optique pour cartographier l'état d'humidité de surface des cavités d'eau salée pour l'année 2017.....	168
4.4	Discussion	173
4.4.1	Suivi de la salinité du sol et des états d'humidification / sécheresse des surfaces autour des cavités d'eau permanentes	174
4.4.2	Origine des cavités permanentes d'eau salée de la Sebkha d'Imlili.....	177
4.4.3	Proposition du flux de travail pour le développement d'un JN d'alerte précoce pour la préservation des écosystèmes naturels.....	178
4.5	Conclusions	179
Chapitre 5 : Cartographie mobile, apprentissage automatique et jumeau numérique pour la surveillance et la maintenance de l'état de santé des ponts : Cas du pont Mohammed VI au Maroc		181
5.1	Introduction	181
5.2	Différence entre JN et BIM.....	184
5.3	Les caractéristiques et capacités clés d'un JN pour les ponts.....	186
5.4	Pont Mohammed VI.....	189
5.5	Matériel et méthodes	190
5.5.1	Le scanner laser mobile Leica Pegasus Two	190
5.5.2	Acquisition et modélisation des ponts	191
5.5.3	Post-traitement du nuage de point acquis par le scanner laser mobile Leica Pegasus Two	192
5.5.4	Modélisation BIM infra du pont Mohammed VI et intégration BIM SIG	193
5.6	Inspection du modèle	199
5.6.1	Analyse du pont au sein de son environnement spatiale.....	199
5.6.2	Auscultation Volumétrique.....	200
5.6.3	Inspection d'alignement, de distorsion et de planéité du tablier du pont	201
5.7	Proposition du JN pour le pont.....	202
5.7.1	Le JN comme solution proposée pour la surveillance continue de la structure du pont à l'aide de capteurs IoT placés sur le jumeau physique.....	202
5.7.2	Flux de travail pour le JN proposé pour la surveillance et la maintenance de pont Mohammed VI en utilisant les algorithmes ML/DL.	203
5.8	Conclusion.....	204
Chapitre 6 : Discussion générale		206
6.1	Introduction	206

6.2	Pourquoi le choix des provinces Sud du Maroc	208
6.3	L'apport des algorithmes d'IA et de la méthodologie collaborative proposée	211
6.4	Conclusion.....	214
Partie 2 : Conclusion.....		215
Conclusion Générale et Perspectives		216
Références Bibliographiques		220

List of Figures

Figure 1 Approche classique : travail de manière autonomes et isolées.....	25
Figure 2. Approche par systèmes numériques distribués et en réseau dans leurs processus de travail orienté nuage (cloud)	25
Figure 3. Technologies JN à l'intersection du Big Data géospatial, IoT et ML	30
Figure 4. Flux de travail pour développer des Jumeaux Numériques : les flèches en noir sont pour le cas du JN pour le pilotage des infrastructures et en rouge ceux pour les écosystèmes naturels et les zones à risque.	34
Figure 5 La multidimensionnalité du pixel de la donnée de télédétection	42
Figure 6. Organisation de la métadonnée des données d'OT.	43
Figure 7. Les quatre dimensions pour du Big data géospatial (Laney, 2001)	44
Figure 8. Comparaison de la taille des données satellitaires par 100 km ² et par année (Laney, 2001).	44
Figure 9. Grande variété de données d'OT.	46
Figure 10. Conception du classificateur : cycle de conception paramétrique et non paramétrique.	53
Figure 11. Exemples de modèle de ML paramétrique et non-paramétrique.....	54
Figure 12. Les étapes d'une classification par ML en utilisant l'approche pixel	61
Figure 13. Cas de données simples : a- Plusieurs limites de décisions sont possibles b- SVM recherche d'un hyperplan qui maximise la marge autour de celui-ci c- représentation de l'hyperplan et des vecteurs de support. (Mantero et al., 2005).....	65
Figure 14. Représentation de l'hyperplan et des vecteurs de support et de la marge. (Mantero et al., 2005)	66
Figure 15. Projection de l'espace d'origine où les données ne peuvent être séparées par la SVM dans un espace des caractéristiques où les données sont séparables linéairement par la SVM. (Mantero et al., 2005).....	67
Figure 16. Cas de données plus complexes : a- Espace d'origine à deux dimensions où la recherche d'hyperplan linéaire est impossible b- Espace des caractéristiques de plus grande dimension où la recherche d'hyperplan linéaire est possible. (Mantero et al., 2005).....	68
Figure 17. Exemple de fonction noyau pour faciliter la classification des données là où elles pourraient être divisées linéairement par un plan. (Mantero et al., 2005)	69

Figure 18. Exemples de fonctions noyau a- linéaire b-polynomiale de degré $d = 2$ c- Gaussienne de paramètre $\gamma = 1$, (Mantero et al., 2005).....	70
Figure 19. Schéma de principe de la classification RF (Breiman, 2001).	75
Figure 20. Traitement du nuage de point 3D : le processus classique basé sur la reconstruction 3D, la modélisation 3D et l'extraction des objets en (a) ; ML/DL processus basé sur l'interprétation du nuage de point en (b). (Modifié d'après Nikoohemat et al., 2017).....	80
Figure 21. Concept de JN (modifié à partir de Madni et al., 2019).	84
Figure 22. Barrage de Sakia El Hamra à gauche (septembre 2016), la crue éclair entraînant l'ouverture de deux brèches de 100 m dans le corps du remblai au niveau du lit mineur de l'Oued (représenté par des cercles à droite- image de la main, prise en décembre 201.....	96
Figure 23. Zone d'étude.	99
Figure 24. Séquence d'inondation. (a) Image de référence = Moyenne de MSI et OLI avant inondation. (b) Sentinel-2 MSI un jour après une crue éclair. (c) Sentinel-1A trois jours après une crue soudaine. (D) Landsat-8 OLI deux semaines après les inondations.	103
Figure 25. La méthodologie collaborative spectrale et catégorique représentée sous forme de flux de travail.	109
Figure 26. Indices extraits de l'OLI deux semaines après l'inondation: (a) indice d'humidité à différence normalisée (NDMI), (b) albédo, (c) indice d'eau à différence normalisée (NDWI), et (d) sécheresse multibande normalisée indice (NMDI).	112
Figure 27 Espace des caractéristiques (Δ (NDMI), Δ (albédo)).	113
Figure 28. Diagramme de dispersion et courbe de régression linéaire de l'espace des caractéristiques (Δ (NDMI), Δ (Albedo)).	114
Figure 29. La direction et l'ampleur du changement dans l'espace des caractéristiques (Δ (NDMI), Δ (Albedo)) en utilisant les positions d'un pixel dans l'image de référence à la date T1 et du même pixel à une date ultérieure T2 après l'évènement.	115
Figure 30. La méthodologie appliquée aux données du radar à synthèse d'ouverture (SAR) représentée sous forme de diagramme de flux.....	122
Figure 31. Histogramme des images de changement.....	123
Figure 32. Δ (Albedo) Variation de l'indice de l'OLI deux semaines après l'évènement.	124
Figure 33. RVB composite couleur (rouge = Δ (albédo), vert et bleu = Δ (NDMI)) pendant (a) un jour après, (b) deux semaines après et (c) deux mois après l'inondation.	125
Figure 34. Résultat de la classification des machines à vecteurs supports (SVM) pour (a) avant l'inondation, (b) un jour après l'inondation et (c) deux semaines après l'inondation. ..	126
Figure 35. Carte des changements (a) un jour après l'inondation, (b) deux semaines après l'inondation et (c) deux mois après l'inondation.	128
Figure 36. (a) Composition colorée des canaux co-registrés des bandes de polarisation VV. Rouge: après inondation; bleu et vert: avant inondation. (b) Carte des changements. Rouge: augmentation de la rétrodiffusion; bleu: diminution de la rétrodiffusion.	130

Figure 37. (a) Étendue de l'eau du barrage avant l'évènement de crue éclair, (b) un jour après l'évènement, (c) deux semaines après l'évènement, et (d) deux mois après l'évènement.	131
Figure 38. (a) Étendue d'eau de Sebkha avant la tempête et (b) un jour après, (c) trois jours après, (d) deux semaines après, et (e) deux mois après l'évènement.	132
Figure 39. Profil topographique du nord au sud illustrant la morphologie du Sebkha, ce qui conduit à une plus grande rétention d'eau dans la Sebkha nord par rapport au sud.....	133
Figure 40. Une cavité d'eau permanente dans la Sebkha d'Imlili (a) abritant une faune de l'espèce Tilapia (b).	138
Figure 41. Emplacement de la Sebkha d'Imlili et de ses cavités d'eau salée. (A) Maroc, (B, C) localisation de la Sebkha, (D) prospection d'une partie de la Sebkha contenant plusieurs trous d'eau vue depuis Google Earth (16 janvier 2018).....	144
Figure 42. (a) Modèle numérique de terrain (DEM) avec un réseau hydrologique et des cavités aquatiques, (b) Bande C Sentinel-1 (fréquence centrale de 5,404 GHz) GRD de niveau 1, (c) image Landsat thématique mapper TM-2004, et (d) Sentinel-2 MultiSpectral Instrumen	146
Figure 43. (a) Espace des caractéristiques formé par l'indice de l'eau utilisant toutes les bandes et l'indice de salinité par différence normalisée (ABWI, NDSI) et la ligne de régression de ce plan; (b) Espace des caractéristiques formé par l'indice de polarisat.....	153
Figure 44. Aperçu schématique de l'approche méthodologique suivi dans ce travail (Workflow).	159
Figure 45. Suivi du NDSI de 1984 à 2019 (a-e) et les points vert correspondent à la distribution spatiale de la salinisation du sol mesurées sur le terrain, et (f) corrélation entre le NDSI extrait des images Sentinel-2 MSI 2017 et les mesures de salinité des.....	161
Figure 46. a - e Distribution des classes spatiales de salinisation du sol de 1984 à 2019 par rapport à la salinisation du sol mesuré sur le terrain et reclassé en deux classes, et (f) Histogramme de salinisation des cavités d'eau salée extraites du NDSI reclassé	163
Figure 47. (a - e) Signal SWCI reclassifié en quatre classes de cavités d'eau salée sèches à très humides de 1984 à 2019 par rapport à la profondeur des cavités d'eau salée mesurées sur le terrain et reclassées en deux classes, et (f) Histogramme des états sec /	165
Figure 48. (a – e) Carte d'humidité obtenue à partir de la reclassification du signal MNDPI en quatre classes de non-humidité à forte humidité des trous d'eau de 2015 à 2019 par rapport à la profondeur des cavités d'eau salée mesurée sur le terrain et reclassée en deux classes, et (f) les statistiques de l'état d'humidité des cavités d'eau salée extraites du MNDPI.	167
Figure 49. a) Le signal Sar / Optic Saltwater Cavity Index (SOSWCI) reclassé en cinq classes à partir de 2017 par rapport à la profondeur des cavités d'eau salée mesurées sur le terrain et reclassé en deux classes; b) états secs / humides des cavités d'eau salée p	169
Figure 50. (a) Composition colorée RVB de Sentinel-2 MSI, (b) le SAR Sentinel-1 fusionné avec l'image Sentinel-2 MSI montrant le réseau hydrographique enterré (bleu) mis en évidence par les données radar et le réseau hydrographique superficiel (jaune) mis en évidence.	170

Figure 51. (a) Résultat de la classification par RF appliquée aux 11 ensembles de données multibandes de 2017, et (b) la même image superposée à la position des cavités permanentes d'eau salée de la Sebkha d'Imlili.	172
Figure 52. (a) Graphique des précipitations de 1985 à 2019 généré à l'aide de la plateforme ClimateEngine, et (b) Graphique des précipitations annuelles moyennes obtenu à partir de (Sindikubwabo et al., 2018).	176
Figure 53. Variation temporelle de l'anomalie interannuelle des précipitations estivales (%) entre 1971 et 2010.....	176
Figure 54	176
Figure 55. Suivi de quatre cavités d'eau salée en jaune, vert, bleu et rouge de 2014 à 2018.	177
Figure 56. le JN comme processus à l'intersection des technologies numériques les plus opérationnelles.	184
Figure 57. Flux de travail d'un JN pour une infrastructure routière.	189
Figure 58. Localisation en (a) et une photographie (b) du pont du pont Mohammed VI.....	190
Figure 59. Unité de Scanner Laser embarqué sur véhicule Leica Pegasus à Rabat.....	191
Figure 60. De l'acquisition des données à l'interprétation des données pour l'inspection des ponts.....	192
Figure 61. Nuage de points 3D du pont Mohammed VI obtenu à l'aide du système de cartographie mobile Pegasus Two de Leica Geosystems.	193
Figure 62. Détection des cablature en utilisant la solution Leica Geosystems (Cyclone, Cloudworx).	195
Figure 63. Visualisation du modèle à l'aide du plugin Cloudworx; (b) et (d) Modélisation et reconnaissance des câbles en acier et deux pylône en béton à l'aide de Cloudworx Pro de Leica (c) Modélisation du tablier.	196
Figure 64. Flux de travail pour l'intégration du BIM et du SIG en utilisant l'Extension Esri Data Interoperability sur FME	198
Figure 65. Exemple de migration de données BIM vers SIG pour une structure de pont.	198
Figure 66. La modélisation du pont Mohammed VI a été intégrée dans un modèle de simulation 3D CIM.	200
Figure 67. Inspection d'alignement, de distorsion et de planéité sur un seul tablier du pont.	202
Figure 68. Exemple de notre architecture de capteurs IoT proposée dans le JN du pont Mohammed VI.	203
Figure 69. Flux de travail pour le JN proposé pour surveiller et entretenir le pont Mohammed VI.	204
Figure 70 (a) Interaction de l'onde Radar SAR avec un sol inondé, (b) sol humide et (c) sol sec	210
Figure 71 Indétermination entre le comportement d'un sol sec et rugueux avec un sol humide et lisse.....	210

List of Tables

Tableau 1 Défis de la recherche dans le domaine de la cartographie des Big Data Géospatiales (Robinson et al., 2017)	47
Tableau 2 Comparaison entre les attributs utilisés dans les approches PBIA et OBIA.....	58
Tableau 3 Résumé des techniques de classification des images d’OT	58
Tableau 4 Comparaison entre les deux méthodes RF et SVM à noyau RBF	75
Tableau 5. Les types de méthodes qui sont utiles pour l’analyse des données d’OT	76
Tableau 6 Ensembles de données utilisés dans cette étude.....	100
Tableau 7 Écart moyen et standard des ensembles de données satellitaires Sentinel-2 et Landsat-8 avant et après normalisation.....	105
Tableau 8 Matrice de corrélation.	113
Tableau 9. La matrice d'erreur montrant les performances de précision globale (OA) exprimées en nombre de pixels.....	127
Tableau 10 Superficie (m2) et profondeur (cm) des cavités d'eau permanentes de la Sebkha d'Imlili.	139
Tableau 11 Ensembles de données utilisés dans cette étude et les indices spectraux et polarimétriques extraits de ces données.....	145
Tableau 12. Classification de la salinisation normalisée des sols selon la littérature (Azabdaftari et Sunar, 2016).....	162
Tableau 13 Nombre de pixels de la matrice d'erreur avec une précision globale (OA).	172

Nomenclature

2D Deux Dimensions

3D Trois Dimensions

ADALINE ADaptive LInear NEuron

ALS Airborne Laser Scanning

AM Apprentissage Automatique

ANN Artificificial Neural Network

API Application Programming Interface

BD Base de données

BIM Building Information Modeling

BIM infra Building Information Modeling infrastructure

CAD Computer Aided Design

CART Classification And Regression Trees

CIM City Infomation Model

CNN Convolutional Neural Network

CS Crowd Sourcing

DL Deep Learning

DXF Drawing eXchange Format

ETL Extract, Transform, and Load

FBR Fonction de Base Radiale ou Radial Basic Function (RBF)

FME Feature Manipulation Engine

GML Geography Markup Language

GPU Graphics Processing Unit

GUI Graphical User Interface.

ICEYE SAR SAT Synthetic Aperture Radar Satellite

IDS Infrastructure de Données Spatiales

IFC Industry Foundation Classes

IGSCR Iterative Guided Spectral Class Rejection

INSPIRE Infrastructure for Spatial Information in the European Community

IoT Internet of Things

JN Jumeaux Numérique

JSTARS Joint Surveillance Target Attack Radar System

KACST King Abdulaziz City for Science and Technology

KML Keyhole Markup Language.

LODs Level of Details (CityGML)

ML Machine Learning

MLS Mobile Laser Scanning

MNE Modèle d'Elevation Numérique

MNT Modele Numerique de Terrain

MODIS Moderate-Resolution Imaging Spectroradiometer

NASA National Aeronautics and Space Administration

NGA National Geospatial-intelligence Agency

NOAA National Oceanic and Atmospheric Administration

OBIA Object based image analysis (ou analyse des images orienté objet)

OGC Open Geospatial Consortium.

OT Observation de la Terre

PBIA Pixel Based Image Analysis

PCA Principal Component Analysis

PLSV-XL Polar Satellite Launch Vehicle

RF Random Forest

SBD Spatial Big Data

SDI Spatial Data Infrastructures

SIG Système d'Information Géographique

SPBIA Sub Pixel Based Image Analysis

SPLATNet Sparse Lattice Networks pour le traitement des nuages de point laser

SPOT Satellite Probatoire pour l'observation de la terre

SQL Structured Query Language.

SVM Support Vector Machine

TLS Terrestrial Laser Scanning

TM Thematic Mapper

UAV Unmanned aerial vehicle

UML Unified Modeling Language

WFS Web Feature Service

XML Extensible Markup Language

Introduction générale

1. Le contexte général

Les grands défis de ce millénaire – tels que l'urbanisation, l'utilisation rationnelle des ressources, le changement climatique, la qualité de vie des citoyens, la préservation du patrimoine naturel et architectural, le suivi et la surveillance des écosystèmes naturels fragiles, le suivi de l'état de santé des infrastructures routières importantes – sont les dernières tendances en développement économique, social et territorial futur (Commission européenne, 2011). Dans ce scénario, le géospatiale, l'Internet des Objets (IoT), les Systèmes d'information Géographiques (SIG), les Big Data et tout dernièrement la technologie des Jumeaux Numériques (JN) couplés aux algorithmes d'Intelligence Artificielle (IA) peuvent apporter une contribution efficace au suivi des patrimoines écologiques, architecturaux et routiers, en tirant parti des flux de travaux numériques et des technologies provenant d'autres secteurs industriels. Les progrès technologiques récents et rapides dans la capture de la réalité et le stockage des données spatiales augmentent considérablement le volume et la variété des données disponibles pour les géo-scientifiques (Hakdaoui et al., 2020; Hepi et al., 2018; Kraut et Wettergreen, 2010; Bhatia et al., 2013; Sellars et al., 2013). De grandes quantités de données collectées par les différentes plateformes spatiales, aériennes, terrestres et des capteurs IoT nous donne un grand volume de données, posant des défis à l'analyse et à l'interprétation automatique de ces données dans des délais acceptables avec un mode de traitement très classique, séquentiel et isolé (Teluguntla et al., 2018; Liu et al., 2018; Feyyad, 1996; Kraut & Wettergreen, 2010). Avec l'amélioration à un niveau sans précédent de cette capacité à acquérir des données d'OT, la sophistication des instruments laser de capture de la réalité (un scan jusqu'à 2 millions de point/s) et la grande disponibilité des données IoT. Nous sommes entrés dans l'ère du Big Data géospatial. Les données géospatiales montrent clairement les caractéristiques du Big Data. Tous ces changements ont poussé la plupart des chercheurs du géospatial du monde à cesser de travailler de manière autonomes et isolés (fig.1), au profit de systèmes numériques distribués

et en réseau dans leurs processus de travail collaboratif orienté nuage (cloud) et dans un environnement Big Data (fig. 2). Aussi, les outils de traitement ont profité de cette nouvelle infrastructure. Des techniques de classification anciennes tell que les Machines Learning (ML) automatiques se sont avérées très adaptés à ce type d'infrastructure, consommatrices de grand ressources informatiques et qui était très difficile à mettre en œuvre dans le mode de traitement procédural, séquentiel et isolé, chose pour laquelle on les a rangé dans des tiroires pendant longtemps, sont devenu facilement réalisables dans ce nouveau mode distribué (Benedek et al., 2015; Zhou et al., 2017; Maggiori et al., 2017; Zhang et al., 2016; Lyu et al., 2017; Sherrah, 2016; Qi et al., 2016a; Weinmann et al., 2015a, 2015b).




Figure 1 Approche classique : travail de manière autonome et isolée




Figure 2. Approche par systèmes numériques distribués et en réseau dans leurs processus de travail orienté nuage (cloud)

Au centre de ce changement d'approche de travail, l'utilisation intensive des données d'OT, très diversifiées (multisources, multicauteurs, multidimensionnelles, etc.), de plus en plus massives et précises à la fois spatialement, radiométriquement, spectralement et temporellement. Ceci, rend les algorithmes classiques de traitement basé sur une approche paramétrique complètement inefficace. Les techniques ML non paramétriques sont en train de devenir de

plus en plus important, du fait de leur adaptabilité aux traitements des données massives. En particulier, l'apprentissage en profondeur s'est avéré être à la fois une avancée majeure et un outil extrêmement puissant dans de nombreux domaines. Raison pour laquelle, nous allons adopter ces outils de ML non paramétriques comme clé à toutes les problématiques que nous allons traiter dans ce travail de recherche, allant de l'extraction d'informations et détection des changements sur des images d'OT jusqu'à la détection d'objets 3D sur les nuages de point et l'intégration de ces objets dans des plateformes JN.

En OT, l'extraction d'information et des caractéristiques d'objets à partir des images (2D) et l'extraction d'information à partir des données tridimensionnelles (3D) de notre environnement physique jouent un rôle essentiel dans leur compréhension (Grilli et al., 2017). La détection, l'analyse et l'extraction des changements des écosystèmes naturels constituent l'un des sujets majeurs de l'OT (Hakdaoui et al., 2020). Singh (1989) a défini les changements comme un processus de détection et d'identification des différences dans l'état d'un objet ou d'un phénomène en l'observant à différents moments. Les institutions gouvernementales utilisent ces changements détectés sur les images multitemporelles pour élaborer les politiques de suivie, de prévention, de planification et de développement urbain (Hepi et al., 2018; Thunig et al., 2011). Le suivi du rendement et de la productivité des cultures, la surveillance de la dégradation des forêts (Lobell et al., 2015), la gestion et la surveillance des habitats favorables pour les espèces d'animaux protégés (Ngandam et al., 2014), la gestion et la surveillance des écosystèmes naturels fragiles (Hakdaoui et al., 2019; Nagendra et al., 2013), la restauration et la réhabilitation en cas de catastrophe (Guru & Aravind, 2015). L'étude de ces changements à l'échelle régionale fournit aussi des informations cruciales sur les problèmes mondiaux actuels, tels que la fonte des glaces (Racoviteanu et al., 2012), les glissements de terrain (Benchelha et al., 2019), les inondations (Hakdaoui et al., 2019) et l'érosion des sols (Haidara et al., 2019), l'étalement urbain (Zerhouny et al., 2016; Aboelnour et Engel, 2018). La solution la plus pratique pour extraire les informations à jour sur les objets et écosystèmes naturels consiste à appliquer des techniques de classification sur les images d'observation de la terre (Zerhouny et al., 2018; Shalaby & Tateishi, 2007).

Plus récemment les données tridimensionnelles (3D) de notre environnement physique ont commencé à jouer un rôle important dans le domaine de l'extraction des caractéristiques des objets tridimensionnels (3D), en tant que sous-ensemble du problème général de l'extraction des caractéristiques d'objets en OT, ces données se caractérisent par leur source de données supplémentaires (hauteur, profondeur ou informations 3D complètes) et les résultats possibles (différences volumétriques / de hauteur). Ces données peuvent servir pour la génération des modèles virtuels de jumeaux numériques de ville en 3D, des nuages de points acquis par un laser ou par des modèles d'élévation numériques (MNE) fournissant des positions / formes 3D explicites des objets au sol, ou des images à vue stéréoscopique / à vues multiples susceptibles de générer de telles informations 3D explicites. La détection en 3D est un sujet relativement nouveau, fortement motivé par la démocratisation des instruments de capture de la réalité (laser terrestre, laser mobile et laser aéroporté, etc.) et l'accessibilité croissante aux données 3D et les besoins de développer des JN intelligents 3D pour les villes (Shaikh et al., 2017; Buyuksalih et al., 2018; Daniel et Doran, 2013; Gruen, 2013). Avec cette nouvelle information tridimensionnelle, le champ des applications d'extraction d'informations peut être considérablement étendu à un espace 3D complet, avec une flexibilité permettant de détecter les changements de vues et de niveaux de détail (LOD ou Level of Detail), y compris la mise à jour du modèle de ville 3D CIM (City Information Model), la surveillance et la maintenance des bâtiments et des infrastructures routières importantes de la ville par la technologies des JN (Tian et Dezert, 2018; Gstaiger et al., 2018; Kim et al., 2013; Torres-Sánchez et al., 2014). En effet cette technologie va permettre aux planificateurs d'optimiser les performances des villes en matière de gestion intelligente des bâtiments, des infrastructures de circulation, des réseaux énergétiques et de gestion de l'eau, de résilience aux catastrophes naturelles, de durabilité et de croissance économique.

2. Problématiques de la thèse

L'évolution de la technologie et l'émergence de nouvelles tendances dans les sciences géospatiales au cours des dernières années ont amélioré l'efficacité de l'utilisation des données

géospatiales pour cartographier, surveiller, rechercher et suivre les écosystèmes terrestres, en particulier les plus fragiles tels que les zones humides sahariennes, les zones à risque d'inondation et les infrastructures importantes de la ville. Cependant, ces nouvelles tendances ont également posé plusieurs défis, notamment: (1) la disponibilité de flux de données satellitaires multicapteurs, multirésolutions et multitemporels en libre accès et l'augmentation de ce volume de donnée par d'autres sources tel que les objets connectés (IoT et les réseaux sociaux, etc.) a rendu le mode de traitement locale classique complètement inapproprié ; (2) travailler en mode distribué nécessite le développement des infrastructures Big Data géospatiales sous la forme d'un cube de données.

Trois cas d'applications seront développés dans ce travail de recherche :

Dans le premier cas la motivation est basée sur le fait que dans la littérature, il est très rare de faire un suivi des changements intervenus dans la réaction des rivières et des zones humides désertiques aux crues éclair (flash flood). Aussi, cette recherche représente une opportunité d'étudier la réponse de cet écosystème désertique à l'effet de cet événement très bref et rare dans cet environnement en utilisant des données spatiales.

Dans le deuxième cas, notre motivation est basée sur le fait que la Sebkha d'Imlili est classée comme écosystème Ramsar, vestige d'un ancien réseau aquatique au Sahara et constitue un domaine d'étude intéressant pour les scientifiques.

Enfin, dans le dernier cas, notre motivation vient du fait que ce pont est le plus long pont à haubans d'Afrique fabriqué avec une technologie de pointe et reliant les principales autoroutes desservant le sud, le centre, le nord et l'est du pays. Ce pont mérite donc, d'être bien suivi et surveiller en permanence de manière automatique en utilisant cette nouvelle technologie des JNs.

3. Les hypothèses de la thèse

Dans ce travail de recherche, nous supposons que la consommation et le traitement de ces données massives doit passer par le développement d'applications tell que les JN travaillant

dans un environnement distribué et en temps réel. Aussi, l'utilisation croissante des algorithmes d'apprentissage automatique non paramétriques sont plus adaptés à ce type d'environnement.

Non seulement les données d'OT augmentent en nombre et deviennent plus faciles d'accès, mais la plateforme d'infrastructure spatiale est également devenue trop sophistiquée pour être traitée par des algorithmes qui ont été construits pour un environnement local et isolé. Néanmoins, ces avancées ont facilité l'intégration d'ensembles de données géospatiales massives et les ont mis à la disposition d'un plus grand nombre d'utilisateurs dans le monde. Ainsi, avec ce développement des techniques d'imagerie spatiale, de plus en plus de données multi-sources, multiplateformes, multicateurs, multirésolutions et multitemporelles sont disponibles, telles que les images optiques (données de réflectance et émittance), les images SAR (données polarimétriques et interférométriques) et données LiDAR installées sur des satellites, des avions, des drones et des plateformes au sol. En plus, la disponibilité des données issues des capteurs et objets connectés (IoT) et des réseaux sociaux, de nature généralement, plus complexe car non structuré. En outre, en raison de l'ouverture des données spatiales en open data, des données satellitaires et données d'informations géographiques fournies volontairement (crowdsourcing) et en mode collaboratif, telles que celles fournies par Open Street Map, Wikimapia et Google Earth Engine, augmentent chaque jour en volume et en disponibilité. Ces jeux de données spatiales disponibles gratuitement peuvent fournir des données auxiliaires pour aider à la décision dans plusieurs domaines environnementaux. Ainsi, le suivi et la surveillance des écosystèmes naturels fragiles, des infrastructures importantes des villes et des zones à risques pourront être réalisés de manière continue et rendre possible l'étude des processus de suivi de ces écosystèmes, tels que les fonctions des zones humides, l'état de santé des infrastructures et les systèmes d'alerte précoce en cas de catastrophe naturelle. Une analyse et une supervision inadéquates de l'état d'humidité du sol peuvent entraîner de nombreux problèmes pour l'écosystème, tels que la perte, la destruction et la dégradation de l'habitat de différentes espèces (Harwood et al., 2016). Il est donc extrêmement important de supposer que la surveillance de ces infrastructures et de ces écosystèmes naturels à l'aide de plateformes numériques appelé JN communiquant de manière bidirectionnelle avec leurs

jumeaux réels en temps réel et que nous devons développer de manière continue sous la forme d'interfaces informatiques. Ces JN représentent une technologie à l'intersection de trois domaines fondamentaux (Fig. 3).




Figure 3. Technologies JN à l'intersection du Big Data géospatial, IoT et ML.

4. Objectives et Motivations de la recherche

Avec l'avènement de l'Internet des objets (IoT), des Big Data géospatiaux et des algorithmes d'IA en mode distribués la technologie JN est devenue très rentable à mettre en œuvre et est de plus en plus utilisée pour modéliser le comportement des systèmes du monde réel, qu'il soit un écosystème naturel à protéger, une zone à risque à surveiller ou une infrastructure urbaine à maintenir, la technologie JN peut prévoir un grand nombre de scénarios qui sont possibles dans chaque cas et permet la modélisation de la vulnérabilité, la résilience dynamique et la simulation en temps réel en reliant les modèles numériques et les simulations avec des données du monde réel pour créer de nouvelles possibilités pour suivre et agir sur ces systèmes fragiles et vulnérables. Un JN peut aider à relever les grands défis de la société civile, y compris la réalisation des objectifs de développement durable tout en tenant compte des problèmes

d'urbanisation rapide, de la croissance démographique et de l'escalade des risques naturels sous l'effet des changements climatiques.

Cependant, pour le développement de ces JN, deux grands défis sont à relever :

- Intégration en temps réel des données multi-sources, multi-échelles et multiplateformes;
- Extraction et classification par algorithmes de ML en temps réel.

Pour extraire de manière automatique les informations à partir des images spatiales et des nuages de point 3D, les techniques de classification ont un rôle très important. Il existe de nombreuses techniques de classification qui peuvent être d'abord partitionné en deux catégories : supervisées et non supervisées selon l'existence ou l'absence de la phase d'entraînement. Ensuite, selon la règle de décision, on peut les regrouper en deux catégories : algorithmes d'apprentissage machine non paramétriques (k-voisins les plus proches, Arbres de décision comme CART, forêt aléatoire, Machines à vecteurs de support à noyau gaussien) et algorithmes d'apprentissage machine paramétriques (la régression logistique; l'analyse discriminante linéaire; Perceptron; la vraisemblance maximale; Réseaux de neurones simples, Machines à vecteurs de support linéaires) (Tayyebi et al., 2014). Parmi ces derniers, la classification de vraisemblance maximale (Maximum Likelihood Classification (MLC)) était le classificateur d'apprentissage machine paramétrique le plus populaire en raison de ses excellents résultats de classification (Emran et al., 1996a, 1996b). Mais les classificateurs paramétriques supposent une distribution normale des données. Or, les données du monde réel ne suivent pas une telle distribution. Au cours de la dernière décennie, les classificateurs d'apprentissage machine non paramétrique sont devenus de puissants classificateurs et ont été largement adoptés pour la classification des images spatiales et la production des cartes thématiques en raison de leur précision et de leurs performances supérieures à celles de MLC (Harris et al., 2015). Les classificateurs d'apprentissage machine non paramétriques ne reposent sur aucune hypothèse concernant la distribution des données et sont par conséquent non contraignantes (Adam et al., 2014). Parmi ces derniers, les plus populaire sont forêt

aléatoire ou Random Forest (RF), Machines à vecteurs de support à noyau gaussien ou Support Vector Machine (SVM). Ils fournissent des résultats très précis pour obtenir des cartes thématiques à partir des images d'OT (Nery et al., 2016; Foody et Mathur, 2004).

Dans les trois cas d'application de ce travail de recherche, les objectifs principaux sont à la fois méthodologiques, thématiques et informatiques.

Ainsi, dans le premier cas d'application, notre objectif était de :

- 1) Développer une nouvelle approche basée sur la collaboration de l'analyse spectrale des images spatiales avec un classificateur d'apprentissage machine non paramétriques SVM à noyau basé sur les fonctions radiales en mode de traitement classique et isolé.
- 2) Cartographier et suivi des changements dynamiques de l'étendue de l'inondation dans l'espace et dans le temps et suivre les états humide / sec de surface après un évènement d'inondation éclair (flash flood).

Dans le deuxième cas d'application, notre objectif est de :

- 1) Développer une approche à la fois basée sur la collaboration des données et des méthodes en utilisant un classificateur d'apprentissage machine non paramétriques RF en mode de traitement distribué en utilisant la plateforme Google Earth Engine (GEE).
- 2) Cartographier et suivre les conditions des états humide / sec de surface autour des cavités d'eau permanentes de la Sebkha d'Imlili qui représente un écosystème de zones humides sahariennes très vulnérables.

Dans le troisième cas d'application, notre objectif est de :

- 1) Réaliser un modèle BIM infra du pont Mohammed VI à partir de données de nuages de points capturées par laser mobile et transformé en objets BIM (par procédé scan au BIM). Celui-ci sera considéré comme socle de la plateforme virtuelle

représentant son jumeau réel et servant pour l'acquisition des données issues des capteurs IoT et pour toute communication bidirectionnelle entre les deux jumeaux ;

- 2) Proposer l'automatisation de la surveillance et la maintenance de ce pont en utilisant des algorithmes ML pour l'extraction des informations utiles à partir des données collectées par les appareils IoT sur l'état de santé de ce pont. En effet, au lieu d'exploiter toutes ces données massives, les algorithmes ML vont identifier et corrélés des clusters de ces données et nous livrer seulement les informations et décisions utiles à prendre.

5. Approche méthodologique

Les données d'observation de la terre constituent un grand support pour beaucoup d'applications environnementales et écologiques. Ceci est possible pour comprendre la hiérarchie de flux de données spatiales pour développer des plateformes JN. Ce flux de travail que nous proposons peut se résumer en quatre niveaux, comme illustré dans le diagramme de la figure 4. Au premier niveau de la hiérarchie se situent les différents types de données spatiales obtenues par satellite, aéroportées ou par drone: multispectral, multitemporelle infrarouge thermique, radar, lidar, des données obtenues depuis le sol comme les lasers terrestre et mobile et des données issues des capteurs IoT. Le deuxième niveau quelques exemples de produits qu'on peut dériver de ces données soit par traitement de classification, segmentation ou analyse spectrale ou autres. Au troisième niveau, l'intégration des données SIG, des données BIM et des données IoT est effectuée. Au quatrième niveau, on trouve la plateforme JN qui va servir pour piloter le jumeau physique (fig. 4). Qu'il s'agit d'un écosystème naturel fragile, d'une zone à risque naturel ou d'une infrastructure urbaine importante dont on cherche à protéger et surveiller son état de santé, ce flux de travail que nous proposons pour développer un JN peut-être appliquer moyennant quelques changements dans les données en entrées et les types de capteurs IoT à installer sur le jumeau physique.

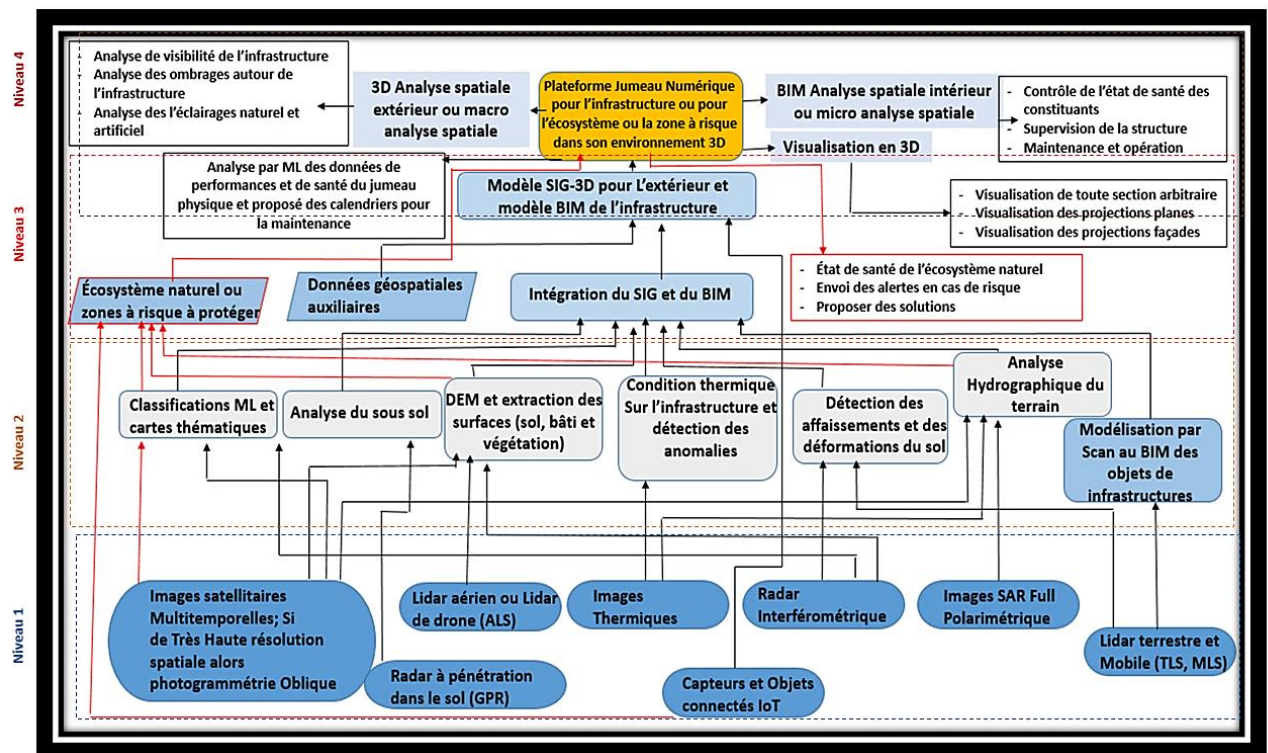


Figure 4. Flux de travail pour développer des Jumeaux Numériques : les flèches en noir sont pour le cas du JN pour le pilotage des infrastructures et en rouge ceux pour les écosystèmes naturels et les zones à risque.

5. Structure de la thèse

Cette étude est conçue pour être lue dans l'ordre afin de comprendre les concepts généraux avant de passer à une description plus détaillée des actions et des recommandations, comme décrit ci-dessous.

Une Introduction générale qui présente l'énoncé du problème, résume les principaux sujets abordés dans une partie consacrée à l'état de l'art et les principaux objectifs et motivations ainsi qu'un résumé de l'approche méthodologique;

Partie 1

Cette partie est consacrée à un état de l'art sur les techniques qui vont être utilisés dans ce travail de thèse à savoir : le Big Data géospatial, les ML et les JN.

Chapitre 1 : est un état de l'art sur le BIG Data géospatial et son importance dans le SIG 3D et pour la technologie JN.

Chapitre 2 : sera consacré à un état de l'art sur les algorithmes de ML appliqués à l'extraction d'information à partir des images spatiales et des nuages de point 3D;

Partie 2

Cette partie constitue la mise en application de ces technologies numériques et sera consacrée aux cas d'études des différents algorithmes d'IA appliqués à des thématiques variées. Elle est constituée de quatre chapitres :

Chapitre 3 : se concentre sur le développement d'une approche collaborative de détection des changements sur l'imagerie spatiale multi-capteurs en combinant les traitements spectraux et les traitements catégoriques basés sur les SVM à noyau gaussien qui est un algorithme ML très populaire. L'objectif est de suivre et voir la réponse des zones humides désertiques à une crue éclair dans le sud du Maroc.

Chapitre 4 : une évaluation des changements dans l'état humide / sec de surface des cavités d'eau de la Sebkha d'Imlili dans le sud-ouest du Maroc en combinant cette fois les données mutisources et multicapteurs avec une combinaison de méthodes spectrales et catégoriques basées sur un algorithme de ML Random Forest (RF), très populaire, en travaillant cette fois dans un environnement distribué (Cloud Computing), utilisant la plateforme Google Earth Engine (GEE).

Chapitre 5 est une application de la convergence de tous ces technologies : géospatiale, IoT, ML dans une plateforme virtuelle JN pour la surveillance et la maintenance de l'état de santé des ponts : Cas du pont Mohammed VI au Maroc.

Le chapitre 6 est une discussion générale des résultats obtenus dans ce travail de recherche.

Enfin, une conclusion générale et des perspectives clotent notre manuscrit.

PARTIE 1 : État de l'art

Partie1 : Introduction

Les technologies émergentes de ces dernières années et les améliorations majeures apportées aux protocoles Internet et aux Systèmes d'Information Géographique (SIG) ont rendu la communication entre différents capteurs (spatiaux, terrestres et mobiles) plus facile que jamais. Selon diverses prévisions, environ 25 à 50 milliards d'appareils devraient être connectés à Internet d'ici 2023. Cela a donné naissance au nouveau concept d'Internet des objets (IoT) récemment développé. Cette ère de digitalisation a également fait place à l'émergence du Big Data spatial constitué des images acquises par les satellites, les avions, les drones, les objets connectés, les applications basées sur la localisation, telles que les bâtiments intelligents, l'infrastructure et les services publics intelligents ; les automobiles autonomes ; le crowdsourcing qui permet de collecter des informations de localisation précieuses 24 heures sur 24. Ainsi, plus les données collectées sont nombreuses, plus l'exploitation de ces données sera complexe. Les Big Data peuvent être utilisées pour créer de nouvelles bases de données SIG ou pour mettre à jour les bases de données existantes en temps réel, offrant ainsi des avantages pour divers secteurs de la ville tels que la planification, la construction, les services publics, les transports, les administrations publiques et l'énergie. Nous vivons à l'ère numérique d'Internet, qui évolue chaque jour et avec les progrès de la technologie, les problèmes d'inhibition de l'Internet moderne ont été libérés grâce à la convergence du Big Data géospatial, de l'IA et de l'IoT. Ces trois domaines de recherche émergents ont un potentiel immense pour aider la société à s'adapter à la croissance démographique et à l'urbanisation croissante et aux problèmes environnementaux. Le Big Data géospatial est généré par une multitude de sources, y compris les satellites, les drones, les lasers terrestre et mobiles, les réseaux de capteurs in situ, les dispositifs de détection, les systèmes et applications de l'IoT, l'Internet social, y compris les médias sociaux, les réseaux, etc. En effet, plus précisément, le Big Data géospatial avec ses flux de données et d'informations offre des références spatiales et géographiques

précises. Les citoyens génèrent des informations et des données qui se combinent pour créer le Big Data géospatial de nombreuses manières - de manière passive (en utilisant des applications, des sites Web, des capteurs, etc., automatiquement avec peu ou absence d'interaction) et manière active avec d'avantage d'interactions telles que le partage de traces GPS, la géolocalisation sociale, messages aux médias, contribuant aux projets d'information géographique bénévoles. Un défi de taille a été soulevé pour obtenir et extraire des connaissances et des informations de ces Big Data géospatiales afin de comprendre, prévoir et gérer le fonctionnement, le changement et la croissance des villes et des zones urbaines. Les villes et les zones urbaines génèrent elles-mêmes des volumes massifs de Big Data géospatiales, de manière directe, indirecte, passive et active. Cependant, il existe peu d'exemples où ces ressources de données ont été efficacement explorées et exploitées dans les études urbaines. Ce qui manque, ce sont les outils d'analyse et de modélisation nécessaires pour exploiter, extraire et convertir ces informations en connaissances. Nous sommes sur le point d'assister à des activités stimulées autour du développement de ces outils, qui transformeront surement le Big Data en quelque chose de nouveau et de puissant. Chaque jour, un grand nombre de capteurs spatio-aériens d'observation de la Terre (OT) de nombreux pays différents fournissent une quantité énorme de données de télédétection. Ces données sont utilisées pour différentes applications, telles que la surveillance des risques naturels, le changement climatique mondial, la planification urbaine, etc. Les applications sont basées sur des données et principalement interdisciplinaires. Sur cette base, on peut vraiment affirmer que nous vivons à l'ère du Big Data d'OT. De plus, ces données représentent un atout économique et une nouvelle ressource importante dans de nombreuses applications. Ceci conduit à une grande transformation du marché de l'OT. De plus, il est maintenant possible de mettre en œuvre le passage de la géologie numérique à la géologie intelligente en intégrant de multiples systèmes dans la recherche géologique grâce à l'utilisation de données Big Data et d'autres technologies comme les traitements distribués (Cloud Computing) (Vermeesch et Garzanti, 2015; Chen et al., 2016; Zhu et al., 2018; Song et al., 2014).

Cette partie présente une revue complète des technologies émergentes de ces dernières années qui sont : Les Jumeaux Numériques (JN), le Big Data géospatial et les Machine Learning

appliqués aux images d'OT et aux nuages de points laser 3D. Cette partie sera divisée en deux chapitres : le premier chapitre sera consacré aux dernières nouveautés et tendances dans le domaine de l'OT, du Big Data Geospatial et à la technologie des JN. Dans le deuxième chapitre, nous allons nous concentrer sur un état de l'art dans le domaine des algorithmes d'Intelligence Artificielle appliqués aux images d'OT et aux nuages de points laser 3D.

Chapitre 1 : Le Big Data géospatial

1.1 Introduction

Chaque jour, un grand nombre de capteurs spatiaux et aériens d'observation de la Terre (OT) de nombreux pays différents fournissent une quantité énorme de données de télédétection. Ces ensembles de données comprennent différentes largeurs de bande spectrales (multidimensionnalité), résolutions spatiales (multirésolution) et résolutions radiométriques (multicapteurs). Combinées aux activités humaines et aux données issues des sciences sociales, les énormes données de télédétection (composées de mégadonnées en télédétection) ont été utilisées avec succès pour différentes applications, telles que la surveillance des risques naturels (Hansen et al., 2013 ;), la gestion et la surveillance des habitats favorables pour les espèces d'animaux protégés (Ngandam et al., 2014), la gestion et la surveillance des écosystèmes naturels fragiles (Hakdaoui et al., 2020 ; Nagendra et al., 2013), la restauration et la réhabilitation en cas de catastrophe (Guru & Aravind, 2015), les glissements de terrain (Benchelha et al., 2019), les inondations (Hakdaoui et al., 2019) et l'érosion des sols (Haidara et al., 2019), l'étalement urbain (Zerhouny et al., 2016 ; Aboelnour et Engel, 2018). Dans la détection des changements à partir des images spatiales le grand défi est de séparer les vrais changements thématiques de ceux qui sont seulement spectrales. Pour cela il faut choisir des images qui sont captées à des moments similaires de la journée (pour avoir le même éclairage). Cette condition est souvent réalisée dans les milieux désertiques. Il faut aussi avoir des images captées au cours de la même saison (afin d'éviter les changements de végétation). Cette condition est souvent vraie car la végétation est rare dans les milieux désertiques. Enfin, il est nécessaire d'avoir une absence de couverture nuageuse qui est une condition souvent réalisée dans les milieux désertiques.

1.2 Les particularités du Big Data géospatial

Au cours de la dernière décennie, le « Big Data » est devenu un terme technique de pointe dans les universités, l'industrie, les entreprises et la politique. Les Big Data font référence à la croissance rapide des données qui dépasse les capacités des bases de données et des outils logiciels traditionnels en termes d'acquisition, de stockage, de traitement et d'utilisation des données (Chen et al., 2016; Manyika et al., 2011). Associé à la caractéristique «4Vs », le big data a créé de nouvelles opportunités (Stantic et Pokorný, 2014) et des défis importants (Chen et al., 2016; Kanchi et al., 2015, Lee et Kang, 2015, Shi et al., 2019).

De nos jours, notre capacité à acquérir des données d'OT a été améliorée à un niveau sans précédent. Nous sommes entrés dans l'ère du Big Data d'OT. Les données d'OT montrent clairement les caractéristiques du Big Data. Le Big Data d'OT attire de plus en plus l'attention des projets gouvernementaux, des applications commerciales aux domaines académiques.

Avec l'avènement de l'Observation de la Terre à haute résolution, nous avons des capteurs avec une résolution spatiale, une résolution temporelle, une résolution spectrale et radiométrique encore plus élevées. En conséquence, nous avons un grand nombre de satellites et de capteurs avec des résolutions différentes. Pour la résolution spatiale, les satellites à haute résolution incluent HJ-1C (5 m), SPOT-5 (2,5 m), IKONOS (1 m), Quickbird (0,61) et Orbview-5 (0,41 m), Mohammed VI A et B (0,5m). Les satellites à résolution moyenne sont les satellites de la série LandSat (LandSat-5 TM (30 m), LandSat-7 ETM+ (15 m) et LandSat-8 OLI (15 m)). Les satellites à basse résolution impliquent NOAA (1 km), MODIS (250 m) et FY 1 à FY-3. Compte tenu de la résolution temporelle, le cycle de repassage de SPOT durerait de 1 à 4 jours, tandis que la NOAA ne prendrait que quelques heures. Du point de vue spectral, le capteur Hyperion est constitué de 220 bandes spectrales avec une résolution de 10 nm, l'instrument WIS dispose de 812 bandes, ainsi que l'imageur hyperspectral équipé en HJ-1A de 128 bandes. De cette manière, les données RS avec leur grande variété de résolutions spatiales, spectrales et même temporelles différentes entraîneraient inévitablement la

complexité des données de télédétection. D'autre part, les applications de télédétection régionales ou mondiales telles que le changement climatique mondial ou l'estimation globale du rendement en grain exploitent des données de télédétection multitemporelles et multispatiales issues de différents capteurs à des fins de traitement. Évidemment, ces avancées conduisent toujours à la multi-dimensionnalité du pixel, comme illustré dans la figure 5.




Figure 5 La multidimensionnalité du pixel de la donnée de télédétection

En outre, la complexité des données de télédétection réside également dans les métadonnées organisées en structures de données complexes. Comme le montre la figure 6, les données de télédétection consistent en métadonnées abondantes pour une description automatique, y compris une image pour décrire la taille de base et les informations de type des données d'image, des informations cartographiques indiquant la position géographique des données, telles que des coordonnées de latitude / longitude de l'image. Le paragraphe de projection inclut certains paramètres de projection géographiques structurés qui varient selon les méthodes de projection. La structure de données complexe pour organiser les métadonnées rend également l'utilisation facile des données de télédétection plutôt simple. L'autre facteur à prendre en compte est que les données d'OT sont naturellement réparties géographiquement. Pour une longue analyse de série chronologique, cela pose des problèmes de gestion et d'exploitation des données d'OT couvrant de grande région puisque ces données sont distribuées localement.




Figure 6. Organisation de la métadonnée des données d'OT.

Le big data géospatiale peut être principalement caractérisé par quatre caractéristiques : volume, variété, vitesse et véracité, définis comme «4V» dimensions par Meta Group Gartner en 2001 (Laney, 2001) (Fig. 7).




Figure 7. Les quatre dimensions pour du Big data géospatial (Laney, 2001)

- **Le volume** : les données archivées se caractérisent par leur augmentation de volume, à partir de Téraoctets ($To = 1024\ Go$ soit 10^{12} octet) en Pétaoctets ($Po = 1024\ To$ soit 10^{15}), et même en Exaoctets ($Eo = 1024\ Po$ soit 10^{18} octets).




Figure 8. Comparaison de la taille des données satellitaires par 100 km² et par année (Laney, 2001).

- **La variété** : En termes de variété, nous pouvons voir maintenant que ces données deviennent de plus en plus diversifiées donnant des big data de télédétection constituée

de sources multiples (laser, radar, optique, etc.), multitemporel (collecté à différentes dates) et multirésolution (différentes résolution spatiale) les données de télédétection, ainsi que des données de différentes disciplines en fonction de plusieurs domaines d'application thématique.

Certaines sources de données qu'on trouve dans le Big data spatial sont (Figure 9) :

- Sentinel 1,2,3,4,5, Landsat1,...8, Spot1,..7, Hyperspectral
- Lidar aéroporté (tour discret, forme d'onde complète, multispectral et monophoton)
- Photos aériennes et nuages de points
- Numérisation laser terrestre
- Données de terrain à référence spatiale
- Données issues de la foule (Crowdsourcing)
- Données personnellement collectées à partir de capteurs embarqués sur drones et d'autres capteurs

Toutes ces données peuvent être organisées en trois classes:

- Données structurées : Comme exemple modèle numérique de terrain, données bathymétriques, raster au format grille et les vecteurs
- Données semi-structurées : exemple les fichiers KML et GML
- Données non structurées : nuage de point et vidéos.



Figure 9. Grande variété de données d'OT.

- **La vitesse ou la tendance vers le temps réel** : la rapidité dans l'augmentation de la taille des big data en OT implique non seulement la génération de données à un taux de croissance rapide, mais aussi efficacité du traitement des données et analyse. Ce cas concerne des données en mouvement et leur transmission peut se faire en secondes ou en millisecondes. En d'autres termes, les données doivent être analysées de manière (presque) temps réel ou un temps raisonnable nécessaire pour accomplir une tâche donnée, par exemple, des secondes peuvent sauver des centaines de milliers de vies dans un tremblement de terre. À titre d'exemple nous citons les informations suivantes :
 - L'ESA collecte 10 To / jour auprès de Sentinel-2A et 2B
 - L'ESA publie 20 To / jour de données
 - Les archives Sentinel de retour à 2014 (S1) sont maintenant > 5 Po
 - L'USGS publie actuellement 1,5 To / jour de Landsat 7 & 8
 - Archives EOSDIS de la NASA 4 To / jour
- **La véracité** : s'intéresse de l'incertitude ou de l'inexactitude des données. Dans de nombreux cas, les données seront précises, donc filtrées de la même manière et la sélection des données réellement nécessaires est une tâche fastidieuse. De nombreux processus statistiques et analytiques doivent viser le nettoyage des données afin de

choisir des données intrinsèques qui peuvent au mieux nous aider pour la prise de décision.

1.3 Défis de la recherche dans le domaine de la cartographie des Big Data Géospatiales

Nous décrivons ici les principaux défis de la recherche à long terme pour la cartographie des Big Data géospatiales, organisées en quatre grands domaines (Tableau 1).

Tableau 1 Défis de la recherche dans le domaine de la cartographie des Big Data Géospatiales (Robinson et al., 2017)

Donner un sens aux Big Data géospatial	▪ Développer des systèmes de raisonnement analytique visuel qui aident les utilisateurs à donner du sens et à organiser ce qu'ils découvrent à partir des Big Data géospatiales ▪ Concevoir des interfaces cartographiques efficaces pour soutenir l'engagement analytique à long terme avec des problèmes spatio-temporels complexes en utilisant les Big Data géospatiales. ▪ Développer de nouvelles approches pour soutenir la prise de décision collaborative en utilisant la carte comme interface mutuelle pour l'analyse des Big Data géospatiales. ▪ Développer des techniques qui permettent aux utilisateurs d'exprimer et de faire correspondre un modèle spatio-temporel qu'ils ont en tête en utilisant la carte comme interface pour analyser les données du Big Data géospatiales. ▪ Comprendre quand, comment et si les cartes créées à partir de cette diversité des données peuvent aider à comprendre le Big Data géospatiale.
Volume	▪ Identifier des méthodes efficaces pour créer des aperçus du Big Data géospatial ▪ Développer des méthodes qui permettent de comprendre le volume du Big Data géospatiale

Variété	▪ Concevoir et développer des interfaces cartographiques capables de gérer la complexité des Big Data géospatiales. ▪ Développer des techniques pour comprendre le changement au fil du temps dans le big data géospatiale. ▪ Élaborer de nouvelles approches pour prendre en charge l'analyse prédictive des phénomènes dynamiques avec des cartes exploitant les Big Data géospatiales. ▪ Développer des méthodes de visualisation spatio-temporelle pour les Big Data géospatiales qui prennent en charge une variété d'utilisations et d'utilisateurs.
Vitesse	▪ Créer des cartes et des interfaces orientées sur les cartes qui attirent l'attention sur les changements importants dans les sources dynamiques des Big Data géospatiales. ▪ Développer des méthodes qui permettent de comprendre la vitesse du Big Data géospatiale.

Chapitre 2 : Les approches d'apprentissage automatiques

2.1 Introduction

L'IA englobe de nombreuses technologies comme l'informatique cognitive, l'apprentissage automatique ou le Machine Learning (ML), la reconnaissance de forme sur les images, la classification des images, le traitement du langage, l'analyse des données, la recherche d'informations, le calcul génétique et évolutif, la découverte des connaissances, la vision industrielle et, bien sûr, le dernier mot clé, l'apprentissage en profondeur ou Deep Learning (DL). Toutes ces techniques ont un fil conducteur et répondent à la question de : comment imiter les facultés humaines comme la vision, les processus de pensée et le raisonnement à l'aide d'ordinateurs ?

Comme tous les systèmes, les SIG contiennent une multitude d'informations classées par leur positionnement géographique, celles-ci constituent d'excellents ensembles de données d'apprentissage pour les systèmes d'IA. Cette connexion à l'IA est naturelle dans le contexte des progrès récents de la vision par ordinateur et de la reconnaissance d'image. À ce jour, il y a eu quelques tentatives réussies d'utiliser le SIG et l'IA pour la gestion de la pollution ou pour contrôler la propagation des maladies (González et al., 2019) en particulier dans le cas de pandémies mondiales.

Malgré les progrès réalisés dans ce vaste domaine de l'informatique, le stockage, la gestion, le traitement et l'exploitation de ces données « volumineuses » détectées à distance constituent toujours un défi de taille. Actuellement, les méthodes d'analyse des données jouent un rôle central dans les géosciences et l'OT. Ceci passe par la collecte de vaste ensemble de données

qui est essentielle pour concevoir une base de données exhaustives du monde qui nous entoure et qui se réalise : sur le terrain par des méthodes d'arpentage, par les satellites, les drones, les réseaux sociaux, les capteurs de la réalité utilisant les technologies Lidar ou photogrammétriques, les IoT, etc. Cependant, l'analyse de ces données devient plus en plus difficile en raison de sa diversité. À l'évidence, ces « données massives » ont des effets notables à la fois sur l'analyse prédictive et sur les outils d'extraction et d'interprétation des données géospatiales. Compte tenu des capacités importantes de l'apprentissage automatique, il semble être une approche très efficace pour traiter ce type de données massives.

Il existe un lien évident entre les développements technologiques en matière d'OT qui nécessitent des algorithmes de traitement plus avancés nécessitant par fois des approches collaboratives combinant des données multisources, multicapteurs et multitemporelles (Hakdaoui et al., 2019 ; Hakdaoui et Emran, 2020 ; Hakdaoui et al., 2020 ; Troya-Galvis et al., 2016). Avec les avancées technologiques en matière d'OT, des capteurs plus avancés sont disponibles, tels que les capteurs hyperspectraux, les lasers d'imagerie et les capteurs multispectraux à haute résolution, capables de produire des données à très haute résolution spatiale. Un premier défi de ces données massives à haute résolution c'est qu'elles nécessiteront des méthodes avancées de traitement des signaux et des images, telles que celles issues des domaines de l'IA et des ML. Grâce à la combinaison de capteurs avancés et de collaboration d'algorithmes de traitement plus intelligents, de nouvelles applications dans différents domaines peuvent être réalisées. Le deuxième défi est l'évolutivité des systèmes. Avec l'augmentation de la quantité et l'ouverture croissantes des données couvrant une large étendue géographique, il existe un intérêt croissant pour le développement de méthodes évolutives capables de produire des cartes de classification multidates sur de vastes zones, à l'échelle des villes, des pays, des continents et de la Terre entière (Mattyus et al., 2015). S'il est urgent de concevoir des algorithmes informatiques efficaces pour traiter des données à grande échelle en utilisant des images à basse et moyenne résolution (Modis, Landsat par exemple), il est également difficile en utilisant des images de très haute résolution spatiales de concevoir des méthodes permettant de produire des cartes précises pour différentes zones de la Terre, compte tenu de la grande variabilité de l'apparence des paysages à travers la planète,

c'est-à-dire une grande variabilité intra-classe. Alors que les premières méthodes de classification en télédétection essayaient de distinguer différentes classes de matériaux et substances de bas niveau (par exemple, eau, sol nu, végétation, roche), les recherches actuelles portent en grande partie sur la segmentation sémantique, où le raisonnement contextuel de haut niveau (par exemple, l'analyse de forme et de contexte) doit être réalisé pour distinguer des classes sémantiques plus abstraites.

Nous allons présenter une revue des algorithmes de ML en approche PBIA pour les problématiques liées à l'OT. Ceci est suivi d'un examen de la théorie qui sous-tend les stratégies ML générales pour l'apprentissage supervisé. Les avantages et les limites de ces stratégies, tels que documentés dans la littérature publiée, sont pris en compte. Ce chapitre se termine par un résumé des ML en approche OBIA.

2.2 Les différents types de classification selon l'hypothèse sur la distribution des données images (Paramétrique et non-paramétrique)

Du point de vue du problème de méthodes statistique de l'apprentissage, nous divisons les statistiques classiques en deux branches : - Les statistiques paramétriques, (maximum de vraisemblance, minimum distance, etc.) dont le cadre suppose que l'on connaît la forme du vrai modèle qui a généré les données, ignorant seulement ses paramètres, et où il s'agit d'estimer au mieux les paramètres du dit modèle à partir d'un échantillon de données fini ; - Les statistiques non paramétriques (k plus proches voisins, fenêtres de Parzen) (fig. 10 et fig. 11). Là, la plupart des études statistiques s'intéressent aux propriétés de convergence et consistance de l'estimateur quand le nombre de parcelles d'entraînement tend vers l'infini.

Le terme « non paramétrique » peut sembler un peu déroutant au début : non paramétrique ne signifie pas qu'ils n'ont aucun paramètre. Au contraire, les modèles non paramétriques

deviennent de plus en plus adaptés avec une quantité croissante de données (fig. 11). Ainsi, dans un modèle paramétrique, nous avons un nombre fini de paramètres, et dans les modèles non paramétriques, le nombre de paramètres est potentiellement infini. Autrement dit, dans les modèles non paramétriques, la complexité du modèle augmente avec le nombre de données d'apprentissage, alors que dans les modèles paramétriques, nous avons un nombre fixe de paramètres (ou une structure fixe). Les modèles linéaires tels que la régression linéaire et les machines à vecteurs de support linéaires sont des exemples typiques de classification paramétrique (fig. 10). En revanche, les forêts aléatoires, les arbres de décision, les plus proches voisins, les K-plus proches voisins, Les SVM à noyau RBF sont considérées comme des algorithmes d'apprentissage non paramétriques car le nombre de paramètres augmente avec la taille de l'apprentissage. – K-voisin le plus proche et arbres de décision, cela a du sens, mais pourquoi un SVM de noyau RBF non-paramétrique alors qu'un SVM linéaire est paramétrique ? Dans la SVM du noyau RBF, nous construisons la matrice du noyau en calculant les distances par paires entre les points d'apprentissage, ce qui la rend non paramétrique. Dans le domaine des statistiques, le terme paramétrique est également associé à une distribution de probabilité gaussienne que les données doivent suivre à priori, et cette distribution est accompagnée du nombre fini de paramètres (par exemple, la moyenne et l'écart type d'une distribution normale). Dans les modèles non paramétriques, ces hypothèses ne sont pas faites. Donc, en termes intuitifs, nous pouvons penser à un modèle non paramétrique comme à un modèle de « distribution » sans hypothèse.




Figure 10. Conception du classificateur : cycle de conception paramétrique et non paramétrique.




Figure 11. Exemples de modèle de ML paramétrique et non-paramétrique.

2.3 L'approche de classification hybride ou collaborative

L'approche de classification hybride ou collaborative fusionne les éléments des algorithmes supervisés et non supervisés (Hakdaoui et al., 2019). Depuis le début des années 1990, plusieurs méthodes hybrides ont également été essayées et affinées dans de nombreux cas pour améliorer la précision de la classification (Liu et al., 2018 ; Tang et al., 2019). Les méthodes hybrides ont montré des résultats significatifs dans les analyses où il existe une variabilité complexe dans les données spectrales au sein des classes d'informations (Tang et al., 2019). L'algorithme de la plupart des méthodes hybrides implique : 1) l'arrangement initial de l'imagerie par regroupement spectral, 2) l'attribution de clusters à des classes définies par l'utilisateur, et 3) la classification de l'image entière à l'aide d'un apprentissage supervisé.

L'Iterative Guided Spectral Class Rejection (IGSCR) est l'un de ces classificateurs hybrides qui utilise des critères de rejet spécifiques et un grand nombre de pixels d'apprentissage pour regrouper les pixels analogues en deux ou trois classes définies par l'utilisateur à travers une séquence d'itérations. Cette méthode accepte et étiquette une classe spectrale si elle atteint le seuil d'inclusion défini par l'utilisateur et la rejette dans le cas contraire. Jusqu'à ce qu'un seuil de convergence soit atteint, les pixels rejetés continuent d'être classés dans la prochaine itération et ainsi de suite. À la fin, la règle de décision supervisée est utilisée pour classer l'image en classes d'informations prédéfinies en utilisant ces classes pures.

2.4 Les différents types de classification selon l'approche utilisée : approche Pixel (PBIA), approche Objet (OBIA) et approche Sub-Pixel (SPBIA)

Il y a plus de quarante ans, les premières approches de classification ont été conçues avec l'apparition des premiers satellites (Kettig et al., 1976), les récents développements technologiques posent de nouveaux défis. Le premier défi consiste à adapter les méthodes de classification aux caractéristiques des nouveaux capteurs, car les méthodes les plus récentes peuvent ne pas être directement applicables ou ne pas donner des performances satisfaisantes. Par exemple, les premiers capteurs satellites ont capturé des données à faible résolution spatiale et des recherches importantes ont été consacrées à la découverte des proportions de matériaux physiques dans chaque pixel en utilisant une approche PBIA (Pixel Based Image Analysis) (Keshava, 2003). Les capteurs récemment développés acquièrent des images à haute résolution spatiale, où les pixels deviennent petits par rapport aux objets. Cela implique la nécessité d'une analyse basée sur les objets ou une approche OBIA (Object Based Image Analysis) c'est-à-dire le développement d'algorithmes qui apprennent à analyser la cohérence et la relation entre des groupes de pixels de l'image, dans le but d'identifier les objets entiers. La segmentation d'image est un terme de vision par ordinateur, avec lequel une image numérique est

partitionnée en un certain nombre de segments homogènes, chacun correspondant souvent à un objet ou à une partie d'un objet (Pal et Bhandari, 1992). Les techniques de segmentation d'images ont été appliquées à la récupération d'images basée sur le contenu, à la détection d'objets, etc. (Pal et Bhandari, 1992). Dans le domaine de la télédétection, une application de segmentation d'image précoce a été développée par Kettig et Landgrebe (Kettig et Landgrebe, 1976), qui ont ensuite développé le classificateur ECHO (Landgrebe, 2003). Dans la segmentation des images de télédétection, des informations spatio-contextuelles ont été incorporées dans les algorithmes, y compris la croissance des régions (Hadi et Salman, 2016 ; Mannan et Ray, 2003), les méthodes markoviennes (Xiang et al., 2017 ; Jackson et Landgrebe, 2002), les méthodes des bassins versants (Jayapriya et Hemalatha, 2019 ; Salembier et al., 1998), et algorithmes hiérarchiques (Pestunov et al., 2015 ; Dalla Mura et al., 2011). Avec l'imagerie segmentée, la technique de classification OBIA (par exemple SVM, classificateur par plus proche voisin k-NN, etc.) peut être appliquée pour dériver des cartes d'occupation du sol. Les techniques de classification d'images basées sur les objets (OBIA) sont considérées comme supérieures par rapport aux techniques traditionnelles basées sur les pixels (PBIA) car elles peuvent incorporer des informations spectrales et spatio-contextuelles dans le processus de classification (tableau. 2) (Jayapriya et Hemalatha, 2019). Un certain nombre d'études récentes ont rapporté des résultats de classification très précis lorsqu'ils sont appliqués à la dérivation de cartes d'occupation du sol à haute résolution spatiale dans les zones urbaines (Rizeei et al., 2018).

La revue de la littérature des approches OBIA en télédétection a suggéré que le classificateur basé sur des règles de décision tel que le classificateur de k-plus proches voisins (k-NN) fait partie des classificateurs d'objets les plus couramment utilisés, popularisés par la disponibilité de logiciels commerciaux tels que eCognition, Erdas imagine ou ENVI. L'approche OBIA utilise la segmentation de l'image et classification par ML sur les résultats de cette segmentation. Globalement, ce processus peut être divisé en deux principales étapes du flux de travail : 1) segmentation multi-résolution et, 2) classification basée sur les ML appliqué à la connaissance des segments. En général, l'algorithme OBIA effectue initialement la segmentation de l'image entière en groupes de pixels conséquents qui sont appelés segments.

Nous définissons ensuite un ensemble de techniques de classification basées ML appliqué des sémantiques sur ces segments (spectrales, spatiales, formes, informations contextuelles et textuelles) pour décrire chaque classe. Par la suite, le classificateur est choisi pour attribuer chaque segment à la classe appropriée selon un ensemble défini de règles de ML. Le tableau suivant (tableau. 2) montre les attributs utilisés dans les deux approches PBIA et OBIA.

Les images d'OT capturées par des à basses résolutions spatiales, moyenne et grossière sont contaminées par des pixels mixtes qui représentent plus d'une classe sur le terrain. Un processus de classification rigoureux peut entraîner une classification erronée d'images remplies de pixels mixtes. Cela peut être dû au fait que la signature spectrale d'un mélange pixel peut ne plus correspondre à aucune des classes de composants ou peut être similaire à la signature spectrale d'une autre classe. Par conséquent, l'allocation d'un pixel mixte à une seule classe peut ne pas être souhaitable en raison de la perte d'informations de la classe associées dans les pixels mixtes. Par conséquent, pour surmonter la présence de pixels mixtes dans les images, des méthodes ont été développées qui décomposent ou fragmentent quantitativement les pixels mélangés en composants primitives de ces classes mixtes. Ce processus est appelé classification sous-pixel, qui a également été appelé demixage spectral (spectral unmixing, décomposition spectrale, classification floue et classification douce). Le processus de classification des sub-pixels décompose une collection de spectres des primitives de classe ou de membres d'extrémité (Endmembers). Ainsi, les méthodes de classification des sub-pixels ont tendance à fragmenter un pixel en divers composants de classe, générant de nombreuses sorties sous forme d'images fractionnaires. Il existe deux principaux types de procédures de classification de sub-pixels : 1) basées sur des modèles linéaires et 2) basées sur des modèles non linéaires ou modèles de fuzzy (tableau 3).

Tableau 2 Comparaison entre les attributs utilisés dans les approches PBIA et OBIA

Attributs	Approche de classification	
	PBIA	OBIA
Spectrale/couleur	Utilisé	Utilisé
Forme/région	Non-utilisé	Utilisé
Surface/taille	Non-utilisé	Utilisé
Texture	Non-utilisé	Utilisé
Contenu	Non-utilisé	Utilisé

Tableau 3 Résumé des techniques de classification des images d'OT

Approches de classification	Caractéristiques	Exemples de classificateurs
PBIA (Pixel Based Image Analysis)	Chaque pixel est supposé être pur et typiquement étiqueté comme appartenant à un seul type d'occupation du sol	Non supervisé (k-means, isodata, algorithmes hiérarchiques, etc.) Supervisé paramétrique (SVM, Max vraisemblance, minimum distance, Mahalabis distance, etc.) Supervisé non paramétrique (k-NN, ANN, arbre de décision, Random forest, SVM à noyau RBF)
OBIA (Object Based Image Analysis)	Objet géographique de type vecteur issu de l'étape de segmentation	Non supervisé (k-means, isodata, algorithmes hiérarchiques, etc.) Supervisé paramétrique (SVM, Max vraisemblance, minimum distance, Mahalabis distance, etc.) Supervisé non paramétrique (k-NN, ANN, arbre de décision, Random Forest, SVM à noyau RBF)

SPBIA (Sub-Pixel Based Image Analysis)	Chaque pixel est considéré comme pixel mixte et nous estimons la proportion de chaque classe d'occupation de sol dans le pixel	Classification floue, ANN, régression, analyse par arbre de régression, analyse linéaire de mixture spectrale, analyse floue de mixture spectrale, etc.
--	--	---

L'apprentissage machine ou ML est une subdivision de l'intelligence artificielle (IA) et couvre également les approches d'exploration de données spatiales et non spatiales (Lary et al., 2016). L'utilisation de la ML / IA a suscité un grand intérêt pour la communauté d'OT et a été largement appliquée à l'analyse des images de télédétection optique. Toutes les méthodes de ML ont été appliquées à l'analyse d'images d'OT. Il y a par exemple les réseaux de neurones artificiels (ANN), classificateurs d'arbres de décision (DT), forêts aléatoires (RF) et machines à vecteurs de support (SVM) (Van der Linden et al., 2007 ; Shang, 2013 ; Petropoulos et al., 2012). Ces algorithmes ne supposent pas de distributions de classes spécifiques et n'ont aucune hypothèse à priori sur cette distribution, et par conséquent ils conviennent donc parfaitement aux environnements complexes ou aux approches utilisant des ensembles de données multisources, multicateurs et multi-échelles qui seront fusionnés dans des approches collaboratives vis-à-vis des données. Plusieurs applications de ML dans l'analyse des images d'OT seront discutées par la suite. SVM et DT peuvent être considérés comme les ML les plus largement utilisés à l'heure actuelle dans l'analyse des images de télédétection optique (Lu et Weng, 2007 ; Wang et al., 2019 ; Mountrakis et al., 2011). Ceci est dû à leur efficacité, leur simplicité et leur disponibilité dans les logiciels commerciaux de télédétection tels qu'ENVI (Exelis Visual Information Solutions), ERDAS Imagine (Hexagone Géospatial). La RF est considérée comme nouvelle pour l'analyse des images de télédétection et l'ANN est trop complexe pour être utilisé largement en OT. Des descriptions détaillées des algorithmes tels que SVM, DT, RF, GA et ANN peuvent être trouvées dans plusieurs textes bien connus sur l'apprentissage automatique et l'intelligence artificielle tels que (Berhane et al., 2018b ; Kotsiantis, 2011 ; Belgiu et Dragut, 2016 ; Breiman, 2001 ; Gislason et al., 2006 ; Belgiu et

Dragut, 2016). Les approches de classification novatrices pour l'imagerie d'OT considèrent chaque pixel comme un motif et toutes les données collectées par les capteurs pour ce pixel sont considérés comme des caractéristiques (par exemple, les valeurs de réflectance dans les différentes bandes spectrales dans le cas d'une imagerie optique). Ensuite, le schéma de reconnaissance de modèle standard (Emran et al., 1996a and 1996b, Jarar Oulidi et al., 2020, Jarar Oulidi, 2019, Jarar Oulidi et Moumen, 2015) est appliqué pour classer chaque pixel (fig. 12) :

1. Le modèle de la règle de décision de classification et ses spécifications sont sélectionnés (par exemple, réseau de neurones, machines à vecteurs de support (SVM), forêt aléatoire (RF), etc.).
2. Le jeu initial de caractéristiques pouvant être redondant, une extraction / sélection de caractéristiques est souvent effectuée, dans le but d'obtenir les caractéristiques qui distinguent au mieux les classes d'intérêt.
3. L'étape suivante, appelée « Apprentissage du classifieur », consiste à partitionner tout l'espace des caractéristiques en K régions exhaustives et non chevauchantes, de sorte que chaque point de cet espace soit associé de manière unique à l'une des K classes. Cela se fait en introduisant dans le modèle de classification des exemples d'échantillons pour chacune des classes (appelés échantillons d'apprentissage). Une fois l'entraînement terminé, chaque nouveau pixel peut être classé en fonction de ses caractéristiques. En fonction du résultat obtenu, il est possible de revenir sur chaque étape pour modifier soit le modèle de décision ou les caractéristiques ou les échantillons d'entraînement.

Cette approche de classification est souvent appelée approche pixel qui signifie que pour classer un pixel, aucune information de son voisinage n'est prise en compte. Différents modèles ont été appliqués pour la classification par pixel, les plus utilisés sont les neurones réseaux (Campolo et al., 2003 ; Foody, 2004 ; Kim et al., 2001 ; Kavzoglu et al., 2003 ; Hsu et al., 1997 ; Hsu et al., 1995 ; Benediktsson et al., 1990) , SVM (Sachdeva et al., 2017 ; Shafizadeh

et al., 2018 ; Tehrany et al., 2014) et forêts aléatoires RF (Tehrany et al., 2014 ; Ham et al., 2005 ; Hansch et al., 2016).




Figure 12. Les étapes d'une classification par ML en utilisant l'approche pixel

Les classificateurs d'apprentissage machine produisent une plus grande précision, même avec des données complexes (Aksoy et al., 2005 ; Huang et al., 2012). Les classificateurs les plus populaires sont (fig.11): Classification and Regression Trees (CART) (Tso et Mather, 2009), forêts aléatoires RF (Tehrany et al., 2014 ; Ham et al., 2005 ; Hansch et al., 2016), k-Nearest Neighbor (k-NN) (Calvo-Zaragoza et al., 2015), Support Vector Machine (SVM) (Sachdeva et al., 2017 ; Shafizadeh et al., 2018 ; Tehrany et al., 2019), réseau de neurones artificiels ANN (Campolo et al., 2003 ; Foody, 2004 ; Kim et al., 2001 ; Kavzoglu et al., 2003 ; Hsu et al., 1997 ; Hsu et al., 1995 ; Benediktsson et al., 1990). Certains de ces classificateurs, tels que CART, construisent un arbre de décision simple à partir d'un sous-ensemble aléatoire de

données de formation pour construire plusieurs arbres de décision. D'autres classificateurs, tels que ANN, suivent un modèle de réseau neuronal et construisent plusieurs couches de nœuds pour transmettre les observations d'entrée pendant le processus d'apprentissage (Perceptron à plusieurs couches) jusqu'à atteindre une condition de terminaison (Mas et al., 2008). Les k-NN utilisent les informations sur les pixels voisins pour développer une compréhension du modèle sous-jacent du jeu de données d'entraînement (Calvo-Zaragoza et al., 2015).

D'autre part, des classificateurs tels que SVM trouvent un sous-ensemble de données d'apprentissage en tant que vecteurs de support en ajustant un hyperplan qui sépare deux classes de la meilleure façon possible (Huang et al., 2002 ; Huang et al., 2012). Parmi tous ces classificateurs, la plupart des littératures suggèrent que RF et SVM ont l'avantage dans la plupart des scénarios de classification car ils surpassent les autres classificateurs de machine (Belgiu et al., 2016 ; Nery et al., 2016). Cependant, il existe un classificateur d'apprentissage machine moins connu, publié par Tipping (Tipping, 2004), RVM, dont les performances seraient meilleures que SVM dans les quelques études disponibles (Heydari et al., 2018). La sous-section suivante décrit en détail les différents classificateurs d'apprentissage automatique faisant l'objet de la présente étude.

Avec la vulgarisation de l'Intelligence Artificielle et son émergence progressive en tant que technologie de base qui entraîne des développements importants dans un grand nombre de domaines, nous assistons également à une accélération de l'utilisation de l'apprentissage automatique (ML) et de l'apprentissage profond (Deep Learning). Selon plusieurs enquêtes et études, l'IA et le ML seraient parmi les domaines les plus lucratifs des années à venir.

L'intelligence artificielle et l'apprentissage automatique révolutionneraient nos cadres technologiques existants et ouvriraient une nouvelle ère industrielle en réorientant et en transformant tout, des appareils les plus simples aux automobiles. Les applications de l'apprentissage automatique ne se limitent pas à la zone terrestre, elles ont également permis d'atteindre le ciel, au sens propre comme au sens figuré. À l'instar de tous les autres domaines qui se réinventent constamment et se préparent pour l'avenir, le domaine de la télédétection subit également de profonds changements et témoigne de l'utilisation croissante d'algorithmes

spécifiques, alors que Big Data et Cloud sont devenus presque omniprésents. Nous allons voir la suite les principaux algorithmes de ML les plus utilisés en OT.

2.5 Les machines à vecteurs de support (Support Vector Machine SVM)

Inventé par le mathématicien russe Vladimir Vapnik au milieu des années 1960 et a été de nouveau bien développées dans les années 1990 (Argialas et al., 1990 ; Kanellopoulos et al. 1999). Elle est connue pour résoudre le problème de séparabilité des classes de manière non linéaire. SVM est une méthodologie d'apprentissage machine automatique théoriquement plus robuste qui donne d'excellents résultats dans la classification des données spatiales de grande dimension. Elle a été jugée compétitive par rapport aux meilleurs algorithmes d'apprentissage automatique. Dans le passé, les SVM étaient testés et évalués uniquement en tant que classificateurs d'images à base d'une approche orientée pixels offrant de très bons résultats (Huang et al 2002, Brown et al 2000, Foody et Mathur 2004 ; Alaa Tharwat, 2019). En outre, pour les données d'OT, il a été démontré que les machines à vecteurs de support avaient un grand potentiel, en particulier pour les données hyperspectrales, en raison de leur grande dimensionnalité (He et al., 2016 ; Gualtieri et Cromp 1999, Melgani et Bruzzone 2004). Dans des études récentes, les machines à vecteurs de support ont été comparées à d'autres méthodes de classification, telles que les classificateurs de réseaux neuronaux, de voisin le plus proche, de vraisemblance maximale et d'arbre décisionnel, et ont surpassé toutes ces méthodes en termes de robustesse et de précision (He et al., 2017 ; Huang et al., 2002 ; Foody et Mathur 2004).

Dans la classification paramétrique, l'objectif est de caractériser les valeurs de chaque classe dans l'espace des caractéristiques. Cela revient à bien connaître la distribution de chaque classe, chose difficile étant donné la complexité des images de télédétection. En revanche, les machines à vecteurs de support (SVM) qui représentent une méthode non paramétrique se

concentre exclusivement sur les échantillons d'apprentissage les plus proches de la frontière entre les classes (Mountrakis et al., 2011 ; Pal et Foody, 2012). Ces échantillons s'appellent des vecteurs de support et donnent à la méthode son nom. Le but de SVM est de trouver la limite optimale, qui maximise la séparation, ou la marge, entre les vecteurs de support. Le classifieur SVM est intrinsèquement binaire, identifiant une limite unique entre deux classes. Cependant, ce problème est résolu en appliquant à plusieurs reprises le classifieur à chaque combinaison de classes possible, même si cela implique que le temps de traitement doit augmenter de façon exponentielle à mesure que le nombre de classes augmente (Cortes et Vapnik 1995). Les SVM ont été conçus à l'origine pour identifier une limite de classe linéaire (c'est-à-dire un hyperplan). Cette limitation a été résolue par la projection de l'espace de fonctions dans une dimension supérieure (fig. 13), en supposant qu'une limite linéaire puisse exister dans un espace de caractéristiques de dimension supérieure. Cette projection vers une dimensionnalité supérieure est connue sous le nom de fonction noyau. Il existe de nombreux noyaux possibles (Kavzoglu et Colkesen, 2009), et chaque noyau peut avoir un ensemble différent de paramètres requis spécifiés par l'utilisateur. Les noyaux couramment utilisés en télédétection sont les noyaux polynomiaux et le noyau à fonction de base radiale (RBF) (Huang, Davis et Townshend 2002).

Pour les classes intrinsèquement non séparables, la limite de décision peut être considérée comme ayant une marge souple. Cela signifie que les échantillons de classe d'apprentissage sont autorisés sur le mauvais côté de la limite, et spécifié par l'utilisateur via le paramètre C , ensuite appliqué à ces points (Cortes et Vapnik, 1995). Ainsi, des valeurs de C plus élevées se traduiront par une limite de décision plus complexe et moins de généralisation.

2.5.1 Principe des machines à vecteurs de support

SVM est une méthode de classification basée sur la réduction du problème de la discrimination entre les classes à celui de la recherche de l'hyperplan linéaire optimal, appelé aussi classificateur à grande marge.

- Cas de modèle linéaire (la recherche d'hyperplan linéaire est simple).

Plusieurs limites de décision sont possibles et tous donnent une précision de 100% sur ces données d'apprentissage (fig. 13). Les SVMs recherchent un hyperplan comme solution à un problème d'optimisation séparant les différentes classes de données. La distance aux points d'entraînement les plus proches est appelée « marge » (égal des deux côtés de l'hyperplan) que l'algorithme SVM cherche à maximiser. Tous les autres points en dehors des points « actifs » situés sur les limites et qui sont appelés des vecteurs de support (VS) peuvent bouger librement. La solution ne dépend que des VSs sous contraintes dont les fonctions objectives sont exprimées à l'aide de produits scalaires entre VSs. Les vecteurs de support sont les points de données les plus éloignés de la surface de décision (ou de l'hyperplan). Ce sont les points de données les plus difficiles à classer. Ils ont un impact direct sur l'emplacement optimal de la surface de décision.




Figure 13. Cas de données simples : a- Plusieurs limites de décisions sont possibles b- SVM recherche d'un hyperplan qui maximise la marge autour de celui-ci c- représentation de l'hyperplan et des vecteurs de support. (Mantero et al., 2005)

Il s'agit de trouver la meilleure frontière qui sépare les deux classes, cela revient à résoudre le problème d'optimisation suivant (fig. 14) :

Trouver w pour maximiser m (la marge), avec des contraintes que tous les points soient bien classés




Figure 14. Représentation de l'hyperplan et des vecteurs de support et de la marge. (Mantero et al., 2005)

- Cas de modèle non linéaire (données beaucoup plus complexes ou la recherche d'hyperplan est impossible dans l'espace d'origine) : solution « Astuce du noyau »

Cette astuce du noyau (Kernel) se base sur l'idée suivante : les données continueront d'être mappées dans des dimensions de plus en plus élevées jusqu'à ce qu'un hyperplan puisse être formé pour les séparer (fig. 15). En termes simples, un noyau est une fonction de l'espace dimensionnel inférieur vers un espace dimensionnel supérieur. Projetez l'espace d'origine dans un espace des caractéristiques où les données sont séparables linéairement (fig. 15).




Figure 15. Projection de l'espace d'origine où les données ne peuvent être séparées par la SVM dans un espace des caractéristiques où les données sont séparables linéairement par la SVM. (Mantero et al., 2005)

Généralement l'espace des caractéristiques est de plus grande dimension que l'espace d'origine et dans lequel le problème de recherche de l'hyperplan linéaire est possible (fig. 16).




Figure 16. Cas de données plus complexes : a- Espace d'origine à deux dimensions où la recherche d'hyperplan linéaire est impossible b- Espace des caractéristiques de plus grande dimension où la recherche d'hyperplan linéaire est possible. (Mantero et al., 2005)

Pour une donnée non linéaire, SVM a du mal à classer les données. La solution simple consiste à utiliser l'astuce du noyau. Une astuce de noyau est une méthode simple dans laquelle des données non linéaires sont projetées sur un espace de dimension supérieure afin de faciliter la classification des données là où elles pourraient être divisées linéairement par un plan (fig. 17). Ceci est mathématiquement obtenu par la formule lagrangienne utilisant des multiplicateurs lagrangiens.




Figure 17. Exemple de fonction noyau pour faciliter la classification des données là où elles pourraient être divisées linéairement par un plan. (Mantero et al., 2005)

Cette astuce de sélection d'une fonction noyau est la tâche la plus importante dans la mise en œuvre et le succès du classifieur SVM. Elle est basée sur le théorème de la couverture qui dit « Un problème complexe de classification d'un pixel ou d'un objet présenté dans un espace d'origine de faible dimension non linéaire est plus susceptible d'être séparable linéairement que dans un espace des caractéristiques de plus grande dimension. La puissance des SVM réside dans le fait qu'ils représentent une implémentation robuste et efficace du théorème de la couverture. La formulation SVM révèle que le problème d'apprentissage et de classification ne peuvent être exprimé qu'en termes de produits scalaires entre échantillons, et que seul ce produit scalaire est nécessaire, pas besoin de créer la fonction de mappage. Or, nous ne sommes pas obligés de calculer le produit scalaire dans l'espace d'origine. Il est possible d'utiliser n'importe quelle fonction noyau $K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2}$ étant donné qu'elle correspond implicitement à un produit scalaire dans l'espace des caractéristiques. Les fonctions noyau sont symétriques et positives.

Les SVM fonctionnent en deux étapes : la première consiste à effectuer un mappage non linéaire du vecteur d'entrée x_i sur un espace de grande dimension qui est caché des entrées ou des sorties ; ensuite nous construisons un hyperplan de séparation optimal dans l'espace de

caractéristiques. Une fonction de noyau est introduite dans le produit scalaire pour rechercher implicitement des surfaces de séparation non linéaires, et la transformation non linéaire des données en un espace de fonctions plus grand est induite. Un hyperplan optimal est déterminé à l'aide de points de données d'apprentissage ou du vecteur de support de chaque classe de l'hyperplan à maximiser, et sa capacité de généralisation est vérifiée à l'aide des points de données de validation. Les vecteurs d'apprentissage x_i , sont projetés dans un espace de dimension supérieure par la fonction du noyau. La SVM peut fonctionner avec quelques points de données d'entraînement. Les fonctions noyau peuvent être linéaire (fig. 18a), polynomiales (fig. 18b) ou fonction de base radiale ou gaussienne (FBR) ou Radial Basic Function (fig. 18c).




Figure 18. Exemples de fonctions noyau a- linéaire b-polynomiale de degré $d = 2$ c- Gaussienne de paramètre $\gamma = 1$, (Mantero et al., 2005)

2.5.2 La SVM dans le domaine d'OT

Les SVM sont particulièrement attrayants dans le domaine de classification des images d'OT en raison de leur capacité à gérer avec succès de petits échantillons de données d'apprentissage, produisant souvent une précision de classification supérieure à celle des méthodes traditionnelles (Mantero et al., 2005). Le principe fondamental qui profite aux SVM est le processus d'apprentissage qui suit ce que l'on appelle la minimisation des risques structuraux. Selon ce schéma, les SVM minimisent les erreurs de classification sur des données invisibles

sans hypothèse préalable sur la distribution de probabilité des données. Les techniques statistiques telles que l'estimation du maximum de vraisemblance supposent généralement que la distribution des données est connue à priori. Les SVM ont encore dépassé même les meilleurs réseaux de neurones (Candade, 2004). Cette découverte est particulièrement intéressante dans les applications de télédétection car les données acquises à partir d'images de télédétection ont généralement des distributions inconnues, et des méthodes telles que l'estimation de vraisemblance maximale (MLE) qui supposent un modèle de données multivarié normal ne correspondent pas nécessairement à cette hypothèse. Même si les données, dont la dimensionnalité est supposée correspondre au nombre de bandes spectrales, étaient normalement distribuées, l'hypothèse voulant que la distribution puisse être décrite à l'aide d'une fonction en forme de cloche (gaussienne) cesse d'être bonne, car la concentration des données dans l'espace de dimension supérieure a tendance à être non gaussienne (Fauvel et al., 2008 ; Fauvel et al., 2009). Ce phénomène continuera à se rencontrer en télédétection car de nouveaux capteurs arrivent avec une plus grande résolution spectrale et spatiale et donc plus grande dimensionnalité des données.

Outre les avantages dérivés de la formulation SVM, il existe également plusieurs défis. Le principal inconvénient en ce qui concerne l'applicabilité des SVM est le choix des noyaux. Bien que de nombreuses options soient disponibles, certaines fonctions du noyau peuvent ne pas fournir une configuration SVM optimale pour les applications de télédétection. Des preuves empiriques indiquent que les noyaux tels que la FBR et les noyaux polynomiaux appliqués à la classification SVM des données d'images satellites produisent des résultats différents (Zhu et al., 2016). Une bonne explication sur les noyaux SVM et leurs fonctionnalités est présentée dans de nombreux articles (par exemple, Kavzoglu et Colkesen, 2009). L'influence des paramètres du noyau définis par l'utilisateur est également décrite par Mountrakis et al. (2011) dans leur examen des SVM, où ils concluent que le choix des noyaux constitue un revers majeur pour les SVM. Ceci est démontré par les différents résultats obtenus à partir de différents noyaux. De plus, le choix des paramètres du noyau d et γ influence grandement le rendement des classifications. Bien que certaines littératures suggèrent des moyens de traiter les problèmes

du noyau (Marconcini et al., 2009 ; Noi et al., 2017), les études sont très rares et décrivent un moyen standard de choisir de tels paramètres (par exemple, Chapelle et Bousquet, 2002). Cependant, les SVMs, qui sont considérés comme un classificateur non paramétrique, fait toujours partie des classificateurs populaires car il donne des résultats très précis avec des échantillons d'apprentissage limités tout en généralisant bien les nouvelles données d'entrées. Il fonctionne également bien avec des données de dimension supérieure, ce qui constitue un avantage certain dans le domaine de la télédétection, car des données multispectrales de résolution spatiale, spectrale et temporelle plus élevée sont maintenant disponibles en libre accès (Srivastava et al., 2012 ; Sim et al., 2018). Kranjcic et al. (Kranjcic et al., 2019) ont utilisé la classification SVM pour fournir une combinaison de paramètres pour extraire la végétation urbaine avec un très haut degré de précision, afin d'accélérer la planification urbaine et finalement améliorer les environnements de la ville. Du point de vue des utilisateurs non experts, la théorie des SVM est un peu intimidante, notamment en raison du fait que les variantes les plus efficaces des SVM intègrent souvent des concepts difficiles à comprendre. Cela limite les applications interdisciplinaires efficaces des SVMs. De nombreux tutoriels SVM sont disponibles (tels que Cortes et Vapnik (Cortes et Vapnik, 1995) et Burges (Burges, 1998)), mais aucun d'entre eux ne contient une discussion exhaustive sur le nombre croissant de variantes de SVM nouvellement proposées. Dans le domaine de la télédétection, le manuel de Tso et Mather (Tso et Mather, 2009) serait un bon point de départ pour passer en revue l'ensemble des méthodes de classification des données de télédétection, y compris les SVM.

En résumé, l'approche SVM cherche à trouver l'hyperplan de séparation optimal entre les classes en se concentrant sur les cas d'entraînement placés au bord des descripteurs de classe. Ces points actifs sont appelés des vecteurs de support. Les autres points sont libres de bouger et sont ignorés. De cette façon, non seulement un hyperplan optimal est défini, mais également moins d'échantillons d'apprentissage sont utilisés efficacement ; ainsi, une précision de classification élevée est obtenue avec de petits ensembles d'entraînement (Mercier et Lennon 2003). Cette fonctionnalité est très avantageuse, en particulier pour les données d'OT et plus particulièrement pour l'analyse d'image orientée objet, où les échantillons d'objet tendent à être moins nombreux que dans les approches orientées pixels.

2.6 Random Forest (RF)

Avant de parler de la classification RF, il est essentiel d'expliquer en premier lieu le principe du classificateur par arbre de décision (DT).

2.6.1 Arbre de décision (DT)

Les arbres de décision ou DT sont parmi les classificateurs les plus intuitivement simples. L'arbre de décision est une division récursive des données d'entrée (Colditz, 2015). Par exemple, les données peuvent être divisées en fonction de si la valeur dans une certaine bande est supérieure ou inférieure à un seuil alors nous passons par la branche 1, sinon nous passons par la branche 2. L'analogie avec l'arbre est utilisée pour décrire le modèle global des divisions répétées, avec des branches représentant les chemins à travers les divisions, et les feuilles les valeurs cibles ultimes. Dans le cas d'un arbre de classification, les valeurs des feuilles représentent des classes ; dans un arbre de régression, les valeurs des feuilles représentent une variable continue représentant la moyenne des valeurs des feuilles.

Les DT présentent de nombreux avantages. La logique du modèle peut être visualisée comme un ensemble de règles si – alors. Les DT peuvent utiliser des données catégorielles, et une fois le modèle développé, la classification est extrêmement rapide car aucune autre mathématique complexe n'est requise.

Les problèmes avec les DT incluent la possibilité de générer une solution non optimale et un surajustement. Ce dernier est normalement résolu en élaguant l'arbre, en supprimant un ou plusieurs couches de fentes (c.-à-d. branches). L'élagage réduit la précision de la classification mais augmente généralement la précision du traitement des inconnues (Topouzelis et Psyllos, 2012).

2.6.2 Random Forest (RF)

Les forêts aléatoire ou Random Forest (RF) est un classificateur non paramétrique. Il utilise un grand nombre d'arbre DT afin de surmonter les faiblesses d'un seul DT (Breiman 2001 ; Belgiu et Drăguț 2016). Le « vote » majoritaire de tous les arbres est utilisé pour attribuer une classe finale pour chaque inconnu. Cela surmonte directement le problème que quelques arbres ne sont pas optimaux, mais en incorporant de nombreux arbres, un optimum global devrait être obtenu. Ainsi, plus le nombre d'arbres est grand, plus le résultat de la classification RF est précis. Cette idée est étendue d'avantage en entraînant chaque arbre avec son propre sous-ensemble des données d'apprentissage généré au hasard, et aussi en utilisant uniquement un sous-ensemble des variables pour cet arbre. La combinaison de données d'apprentissage réduites et d'un nombre réduit de variables signifie que les arbres seront individuellement moins précis, mais ils seront également moins corrélés, ce qui rend l'ensemble plus fiable. Les données non utilisées en apprentissage sont connues sous le nom de données hors sac et peuvent être utilisées pour fournir une estimation de la précision globale de la classification RF. En outre, en comparant systématiquement les performances des arbres qui utilisent une bande spécifique et ceux qui n'en utilisent pas, l'importance relative de chaque bande peut être évaluée. Un avantage particulier avec RF est qu'en raison de la présence de plusieurs arbres, les arbres individuels n'ont pas besoin d'être élagués. Un inconvénient est qu'en ayant de nombreux arbres, la capacité de visualiser les arbres est effectivement perdue (Breiman, 2002). L'idée de base des RF est de construire plusieurs arbres avec une division « aléatoire » et des résultats moyens. Aussi, l'intérêt est d'augmenter la vitesse en limitant le nombre d'évaluations séparées et exploiter l'approche ensemble (bagging, boosting....) pour réduire le bruit (fig. 19). Pour initialiser l'algorithme RF, l'utilisateur doit définir deux paramètres. Ces paramètres sont N et m , qui sont les nombres d'arbres à construire et le nombre de variables utilisées pour séparer chaque nœud, respectivement. Tout d'abord, n échantillons bootstrap sont tirés des $2/3$ de l'ensemble de données d'apprentissage. Le $1/3$ restant, également appelées données hors sac, sont utilisées pour tester l'erreur des prédictions. Ensuite, un arbre non débarrasser de grosses branches qui le surchargent de chaque échantillon de bootstrap est développé de telle sorte qu'à chaque nœud m prédicteurs sont choisis au hasard comme un sous-ensemble de

prédicteurs variables, et la meilleure répartition parmi ces variables est choisie. Il est crucial de sélectionner le nombre de variables m qui fournit une corrélation suffisamment faible avec une prédiction adéquate (Liaw et Wiener, 2002 ; Khalid et al., 2014). Breiman (Breiman, 2001) suggère que le réglage du nombre de variables de chaque arbre (m) égal à la racine carrée de M (nombre de variables globales) donne généralement presque un résultat optimal. RF utilise l'arbre de classification et de régression (CART) algorithme pour créer les arbres (Breiman 2001).




Figure 19. Schéma de principe de la classification RF (Breiman, 2001).

Dans le tableau 4, nous comparons les deux méthodes RF et SVM.

Tableau 4 Comparaison entre les deux méthodes RF et SVM à noyau RBF

Nom	Description	Avantages	Inconvénient
Random Forest	Un groupe d'arbres de décision. Chaque arbre est une hiérarchie des décisions qui divisent les échantillons en deux groupes en fonction de la valeur d'une seule caractéristique à la fois	• Moins sensible au bruit • Peut gérer de grands nombres d'échantillons d'apprentissage • Peut gérer un grand nombre de variables	• L'inconvénient d'un arbre de décision est une grande variance dans ses résultats, les forêts aléatoires résolvent ce problème en faisant la moyenne de nombreux arbres.

			• Plus lent que les autres méthodes surtout dans la phase de test
SVM à noyau RBF	Utilise l'astuce du noyau RBF pour décrire la non-linéarité des différences entre les échantillons d'apprentissage	• Plus approprié pour les situations avec des échantillons d'apprentissage limités • Peut facilement manipuler de grand nombre de caractéristiques d'entrée • Peut connaître les relations nonlinéaire entre les entités	• Complexité informatique lorsqu'il y a un grand ensemble d'entraînement • Données sensibles aux bruits

Dans le tableau 5, nous décrivons les types de méthodes qui sont utiles pour l'analyse des données de télédétection et nous allons fournir des références dans la littérature et les exemples de leur application en OT.

Tableau 5. Les types de méthodes qui sont utiles pour l'analyse des données d'OT

Description de la méthode	Les applications en OT
Régression logistique et multinomiale Types de modèles linéaires généralisés. - La régression logistique est utilisée lorsque les sorties de classification sont catégoriques avec deux niveaux (binaire) (végétation / pas de végétation, haute / basse, présente / absente). - La régression logistique Multinomiale est utilisée les sorties de classification sont a plus de deux niveaux (arbres / herbe / sol nu / culture / eau, haut / moyen / bas).	(Henry et al., 2017) cet article discute de la cartographie des plantations de canne à sucre à partir de l'imagerie satellite Landsat-8 en utilisant la régression logistique. (Hyandye et al., 2015) ont utilisé une régression logistique multinomiale pour déterminer comment l'occupation du sol à Usangu, en Tanzanie, était influencé par un ensemble de covariables; pente, élévation, distance des routes, distance des rivières, densité de population, précipitations annuelles, indice de végétation (NDVI) et types de sols. Les auteurs ont utilisé le modèle multinomial, exécuté sur des données Landsat sur plusieurs années, pour obtenir le changement probable de l'occupation des sols, compte tenu d'un changement d'une unité dans ces covariables. (CENGİZ et al., 2018) dans cette étude, un modèle de croissance urbaine pour l'année 2044 a été établi pour le centre-ville de Malatya (Turquie) et ses environs immédiats en utilisant l'approche de régression logistique multinomiale basée sur la méthode d'estimation empirique et les variables qui sont le moteur de la croissance urbaine.
Machines à Vecteur de Support (SVM) à noyau gaussien Les SVM à noyau sont une classe de techniques de classification supervisée non paramétrique. Les SVM peuvent être utilisés pour cartographier les vecteurs de support dans des espaces d'entités de dimension supérieure afin de les rendre plus séparables, puis classés dans l'espace d'entrée d'origine. Les fonctions du noyau sont utilisées pour définir ce mappage de l'espace d'entrée vers l'espace de fonctionnalité.	Kranjcic et al. (Kranjcic et al., 2019) ont visé à fournir une combinaison de paramètres pour extraire les espaces vert des zones urbaines avec le plus haut degré de précision en utilisant la SVM, afin d'améliorer les environnements urbains. Waske et Benediktsson (Waske et Benediktsson, 2007) ont classé les données multi-capteurs (SAR, Landsat TM et SPOT) et multitemporelles par fusion de données basée sur les SVM. Leur méthode était basée sur la fusion décisionnelle de plusieurs SVM qui ont été formés individuellement sur les différentes sources de données. Certains articles qui examinent l'utilisation des SVM pour l'analyse des données de télédétection comprennent Szuster (Szuster et al., 2011) pour la classification de l'occupation des sols dans les zones côtières tropicales; Mathur et Foody (Mathur et Foody, 2008) pour la classification des cultures; et Shao (Shao

	et Lunetta, 2012) pour la classification des sols. Tharwat (Tharwat, 2019) fourni des explications utiles sur les noyaux et des conseils sur la façon de sélectionner un noyau approprié pour les SVM.
Arbres de classification et de régression (CART) Une technique de classification supervisée qui est un algorithme non paramétrique qui partitionne récursivement l'ensemble de données par le biais de modèles de régression simples en sous-ensembles de plus en plus petits par le même fractionnement décision (c.-à-d. fonction principale). Chaque modèle de régression simple (c'est-à-dire un plan de régression) n'a qu'une seule variable dépendante et la relation entre les plans de régression est non linéaire. Un arbre de classification fait partie de la famille des méthodes d'arbre de décision, qui incluent les arbres de régression, les arbres boostés, les arbres ensachés, etc. Le principal avantage des arbres de classification en particulier, et des arbres de décision en général, est qu'ils sont simples et faciles à comprendre. En raison de leur simplicité de calcul, ils peuvent être appliqués à de grandes quantités de données.	(Lary, 2010) montre que CART affiche de bonnes performances en régression qu'on classification, et utilise une autre approche qui a consisté à utiliser un modèle d'arbre de régression d'ensemble (c'est-à-dire des arbres additifs ou des « forêts »), qui est un algorithme qui synthétise plusieurs modèles liés mais différents, pour améliorer la précision de l'analyse prédictive. Dietterich (Dietterich, 2000) a développé deux arbres de régression ou plus en fonction de différents sous-ensembles d'échantillons d'apprentissage. Le résultat final du modèle d'arbre de régression d'ensemble est le résultat pondéré basé sur le résultat de chaque arbre. Zhang et al. (Zhang et al., 2019) ont montré que les modèles de régression basés sur des algorithmes d'apprentissage automatique CART appliqués aux images de télédétection permettent d'économiser du travail et du temps pour estimer les indicateurs de la végétation et de l'état de surface aux échelles temporelle et spatiale qui sont impossibles avec les méthodes de terrain. Plusieurs études (Booth et Cox, 2009; Jones et al., 2018; McCord et al., 2017) ont montré que CART appliqué aux images de télédétection peut générer des indicateurs de surface à des échelles de paysage relativement grandes
Forêt aléatoire (RF) Un type de méthode d'arbre de classification, qui est un ensemble d'arbres « peu profonds » construit à partir de nombreux échantillons aléatoires. La méthode combine les résultats de ces arbres pour classer ou prédire les valeurs.	Berhane et al. (Berhane et al., 2019) ont montré l'efficacité et la précision de trois classificateurs différents, les approches DT, RB et RF, utilisant une grande zone humide et ensemble de données sur la végétation et imagerie haute résolution. Ils ont fourni une méthodologie et des recommandations pour classer de manière efficace, efficiente et robuste un paysage de zone humide donné. Reis et al. (Reis et al., 2018) ont appliqué un certain nombre de méthodes pour cartographier l'étendu et volume de la forêt d'Eucalyptus au Brésil, et ont trouvé que la RF était la meilleure méthode pour cette prédiction spatiale, par rapport à d'autres méthodes de régression linéaire multiple, SVM et réseau de neurones artificiels. Schmidt et al. (Schmidt et al., 2016) ont comparé un certain nombre de méthodes de classification dans le domaine de l'estimation du rendement des cultures en Australie en utilisant l'imagerie Landsat, et ont constaté que les RF ont fourni la meilleure précision et robustesse.
K plus proche voisin (K-NN) Une technique de classification non paramétrique bien connue et populaire pour sa relative simplicité. Dans sa forme la plus simple, une observation est classée selon un vote majoritaire de ses k voisins les plus proches. La classe d'un objet est attribuée par la plus courante parmi ses k voisins les plus proches, où k est généralement un petit entier positif. Bien que les méthodes du plus proche voisin soient conceptuellement attrayantes et rapides en termes de calcul, ils ne sont pas toujours le meilleur modèle pour les données de télédétection et sont parfois combinés avec d'autres méthodes dans ce contexte.	Fu et al., (Fu et al., 2019) ont appliqué kNN à toute la Chine du Nord-Est, puis ils ont évalué la performance de différents modèles pour développer un modèle kNN optimal pour cartographier la biomasse forestière hors sol au niveau des espèces; Ils ont aussi étudié la relation entre les variables environnementales (par exemple, le climat, la topographie, le sol) et la biomasse forestière aérienne au niveau des espèces en utilisant la kNN. Wilson et al., (Wilson et al., 2012) la kNN a été utilisé pour prédire les attributs de la forêt (par exemple, le volume de la tige, biomasse aérienne) sur de grandes régions. Brosofske et al (Brosofske et al., 2013) ont que la valeur k optimale (nombre de voisins les plus proches) utilisés pour calculer les attributs forestiers du pixel cible ne sont pas bien définis, et une sélection inappropriée de la valeur k entraînera de grandes erreurs.

	Blanzieri et Melgani (Blanzieri et Melgani, 2008) ont préféré une combinaison de méthodes kNN et SVM pour classification des images de télédétection.
Classification intra ou sub-pixel Ces méthodes peuvent être utilisées pour résoudre le problème des pixels qui ont les caractéristiques de plusieurs thèmes. Les pixels mixtes sont principalement une préoccupation des capteurs basse résolution (par exemple, MODIS) ou moyenne résolution (par exemple, Landsat). Les deux approches les plus courantes dans la littérature sur la télédétection pour le problème de classification des pixels mixtes.	Dimitrov et al (Dimitrov et al., 2019) présente les résultats d'une classification en sub-pixels des types de cultures en Bulgarie à partir de la série chronologique PROBA-V de 100 m d'indice de végétation (NDVI). Deux méthodes de classification sub-pixels utilisant le réseau de neurones artificiels (ANN) et le SVM la sortie était un ensemble d'images de fraction de surface (AFI) à une résolution de 100 m avec des pixels contenant les fractions estimées de chaque classe. Les images Sentinel-2 ont été utilisées pour obtenir des données d'apprentissage pour les classifications sub-pixels. Kumar et al. (Kumar et al., 2019) ont comparé les performances de plusieurs algorithmes d'apprentissage sub-pixel basé sur les moindres carrés, la régression et les méthodes géométriques.

2.7 La faisabilité de l'approche basée sur ML pour le nuage de point

L'absence totale de la structure, de l'ordre et de la sémantique ainsi que de l'irrégularité, de l'incomplétude et de l'ambiguïté inhérentes font généralement des nuages de points 3D des candidats difficiles pour la programmation procédurale et algorithmique. Cependant, leurs caractéristiques nous permettent d'appliquer efficacement ML aux nuages de points 3D pour les raisons suivantes :

- La nature Big Data - Les nuages de points 3D sont des mégadonnées spatiales qui peuvent être générées de manière rentable pour presque tous les types d'environnements spatiaux - les mégadonnées sont une condition préalable pour les approches basées sur ML ;
- La nature flou - Les nuages de points 3D montrent le flou et le bruit inhérents car ils échantillonnent des formes au moyen de représentations discrètes –les algorithmes ML gèrent particulièrement les données flou et rempli de bruit ;
- La sémantique - Selon l'application concrète, les concepts sémantiques peuvent être définis et les données d'apprentissage correspondantes peuvent être configurées.

Les nuages de points 3D, en théorie, sont complexes, expressifs et puissants, mais les nuages de points 3D réellement générés par les lasers sont beaucoup moins complexes, beaucoup moins expressifs et fortement répétitifs. Leurs propriétés statistiques prévisibles peuvent être

capturées dans des modèles de langage statistique et exploitées pour l'analyse des données géospatiales (Bassier et al., 2016 ; Landrieu et al., 2017 ; Lin et al., 2015).

2.8 Interprétation ML basée sur le nuage de point

Les nuages de points 3D fournissent des données brutes économiques pour la construction d'assemblage numériques à toutes les échelles, mais ce sont des données purement géométriques sans aucune information structurelle ou sémantique sur les objets qu'ils représentent. Motivé par l'hypothèse de naturalité, le ML peut être appliqué pour comprendre et reconnaître ces informations : le ML se transforme en une technique puissante s'il s'agit de données discrètes, irrégulières, incomplètes, floues et ambiguës d'un corpus donné, exactement ce qui caractérise les nuages de points 3D.

Le traitement basé sur le ML des nuages de points 3D est basé sur le concept d'interprétation connu des langages de programmation. Les analyses analytiques et sémantiques ne nécessitent pas d'étapes qui « compilent » les données brutes dans des représentations de niveau supérieur. Pour traiter les données, par exemple, le réseau de neurones PointNet « consomme directement les nuages de points et respecte bien l'invariance par mutation des points en entrée » et fournit une « architecture unifiée pour les applications allant de la classification d'objets, la segmentation de pièces, à l'analyse sémantique de scènes (Mura et al., 2016 ; Mura et al., 2014 ; Nguyen et Le, 2013 ; Nikoohemat et al., 2017).

Les applications ou services qui nécessitent des informations spatiales encodées dans des nuages de points 3D spécifient l'ensemble exact d'entités à extraire et l'étendue spatiale à rechercher. Les types de fonctionnalités disponibles dépendent de la manière dont les sous-systèmes ML et DL ont été formés auparavant. L'analyse traite la demande en déclenchant l'évaluation pour obtenir les résultats. À aucun moment, les nuages de points 3D ne sont prétraités ou prévalues et ne nécessitent aucune représentation intermédiaire, c'est-à-dire que l'interprétation fonctionne à la demande sur les données brutes des nuages de points.




Figure 20. Traitement du nuage de point 3D : le processus classique basé sur la reconstruction 3D, la modélisation 3D et l'extraction des objets en (a) ; ML/DL processus basé sur l'interprétation du nuage de point en (b). (Modifié d'après Nikoohemat et al., 2017).

La densité d'échantillonnage non uniforme généralement trouvée dans les nuages de points 3D représente un défi majeur pour l'apprentissage des fonctionnalités ML et DL. (Fig.20) « Les caractéristiques apprises dans les données denses peuvent ne pas se généraliser aux régions à faible échantillonnage. Par conséquent, les modèles formés pour les nuages de points clairsemés peuvent ne pas reconnaître les structures locales à grains fins » (Fang et al., 2015 ; Ioannidou et al., 2017). Par conséquent, Qi et al. (Qi et al., 2016a ; Qi et al., 2016b ; Qi et al., 2017) Proposent un CNN hiérarchique qui fonctionne sur les partitions imbriquées d'un ensemble de points d'entrée.

L'interprétation basée sur ML nous permet d'implémenter des composants d'analyse génériques pour les nuages de points 3D. Comme aucune représentation intermédiaire n'est requise, les résultats d'analyse ne sont créés qu'une fois qu'ils sont demandés et ils sont uniquement calculés pour la région spécifique définie par l'application. Parmi les avantages de cette approche :

- Configurabilité : les données d'apprentissage ML / DL ainsi que les définitions des vecteurs de fonction permettent de prévoir de nombreux types d'étiquettes. Pour

cela, le mécanisme générique indépendant du domaine offre un haut degré de configurabilité.

- Calcul à la demande : les services en aval permettent le calcul à la demande. Pour de nombreuses classifications, l'interprétation peut être exécutée même en temps réel (par exemple, la détection d'objets hors des nuages de points à des fins de surveillance).
- Service-Based Computing : l'approche est évolutive car elle peut être entièrement mappée sur une architecture orientée services et du matériel évolutif (par exemple, des grappes de GPU), construit par des services et des mashups de niveau inférieur et supérieur.
- Traitement des données brutes : le stockage et la gestion de nuages de points 3D massifs, y compris ceux qui varient en fonction du temps, peuvent être optimisés indépendamment, car l'interprétation ne nécessite qu'un accès spatial rapide au contenu des nuages de points.
- Efficacité du stockage : il n'y a pas de modèles présélectionnés ou prédéfinis ni de représentations intermédiaires. L'approche fonctionne donc bien pour des nuages de points 3D massifs ou variant dans le temps. En particulier, la précision d'origine des données brutes n'est jamais réduite car les données brutes sont introduites directement dans les processus ML / DL.

2.9 La classification du nuage de points

Le but de la classification d'objets 3D est de reconnaître des objets d'un nuage de points 3D (Douillard et al., 2010), c'est-à-dire de fournir une étiquette d'objet sémantique à un nuage de points non structuré et séparé, actuellement il y a de nombreuses applications en robotique, en réalité virtuelle et en urbanisme. Les défis de la classification liée aux données ont trois aspects, y compris les données manquantes, le bruit et l'invariance de rotation.

- Données manquantes : les modèles numérisés sont généralement occlus et certaines données sont perdues.
- Bruit : tous les capteurs sont bruyants. Il existe différents types de bruit, y compris les perturbations ponctuelles et les valeurs aberrantes. Cela signifie qu'un point a une certaine probabilité dans un certain rayon autour de l'endroit où il est échantillonné (perturbation), ou qu'il peut apparaître à des emplacements aléatoires (valeurs aberrantes) dans l'espace.
- Invariance de rotation : les points de rotation et de translation ne doivent pas affecter la classification.

La précision est généralement utilisée pour évaluer un modèle de classification. En général, la précision fait référence à la proportion du modèle qui prédit le résultat correct. Formellement, la précision est définie comme dans la formule (1) (Goodfellow et al., 2016). Quant au taux d'erreur, il s'agit du taux de mauvaise classification et égal à une précision moins, comme indiqué dans la formule (2).

$$Précision = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$Erreur = 1 - Précision \quad (2)$$

Où TP, TN, FP et FN sont respectivement le vrai cas positif, le vrai cas négatif, le cas faux positif et le cas faux négatif.

La classification d'objets 3D reçoit de plus en plus d'attention et est devenue un domaine de recherche très actif. Plusieurs méthodes peuvent être utilisées pour la classification, telles que PointNet, PointNet ++, SO-Net, Dynamic voxel CNN, PointCNN, Kd-Network, 3DContextNet, Multi-Resolution Tree Network, SPLATNet, FoldingNet et NeuralSampler. Même s'il existe de nombreux jeux de données disponibles, les jeux de données largement utilisés pour accéder aux performances de divers modèles sont ModelNet 10 et ModelNet 40.

2.10 Le Jumeaux Numérique (JN) ou Digital Twin (DT)

Le concept de JN (DT) a vu le jour pour la première fois en 2001 à l'Université du Michigan par Michael Grieves (Grieves, 2001). Depuis ce temps, le concept a évolué avec l'avènement des IoT. Un JN concerne généralement la représentation virtuelle et précise d'un système, qui peut aller de pièces d'équipement à l'ensemble du processus de création, et a été souvent utilisé par les principaux fournisseurs de solutions de technologie de construction (Berutti, 2019 ; Tsay et al., 2018). Les JN ont suscité un intérêt croissant en raison de leur capacité prétendue à fournir des informations de bonne qualité sur un système donné en temps réel (Rosen et al., 2015 ; Boschert et Rosen, 2016). La vision d'un JN appelle à intégrer les données de géolocalisation, contextuelles, d'imageries spatiales, de drones et d'appareils connectés IoT dans le modèle système virtuel JN pour faciliter l'analyse, contourner les problèmes et développer une technologie permettant d'informer sur l'état actuel et future du système physique réel. En intégrant les mondes virtuel et physique, le JN permet une surveillance en temps réel des systèmes et des processus et l'analyse en temps opportun des données pour éviter les problèmes avant qu'ils ne surviennent, planifier la maintenance préventive pour réduire / prévenir les risques, découvrir de nouvelles solutions et planifier pour les futures mises à niveau et nouveaux développements. La technologie de JN a le potentiel de réduire le coût de la vérification et des tests du système tout en fournissant des informations précoces sur le comportement du système. Aujourd'hui, cette technologie fait partie intégrante de l'initiative d'ingénierie numérique qui vise à connecter les systèmes et les opérations dans un monde de dispositifs physiques de plus en plus interconnectés et intelligents (West et Pyster, 2015 ; Pettey, 2017). Un JN, par définition, nécessite un jumeau physique pour l'acquisition de données et le contexte d'interaction des deux modèles : Le modèle de système virtuel dans le JN sous forme de maquette BIM peut changer en temps réel selon l'état des changements du système physique (pendant toutes les étapes depuis la conception jusqu'à la démolition). Aujourd'hui, un JN se compose de produits, en utilisant généralement l'IoT, et une connexion numérique. La connexion numérique assure la connectivité tout au long du cycle de vie du

système et collecte les données du jumeau physique pour mettre à jour ces modèles. La figure suivante (fig. 21) présente le concept de JN.




Figure 21. Concept de JN (modifié à partir de Madni et al., 2019).

Comme le montre la figure 21, le JN relie les environnements virtuel et physique. L'environnement physique comprend le système physique, les capteurs IoT embarqués et externes, les interfaces de communication, et éventuellement d'autres appareils fonctionnant dans un environnement ouvert avec accès aux données de positionnement GPS de ces appareils. Tous deux opérationnels et les données de maintenance associées au système physique sont fournies à l'environnement virtuel pour mettre à jour le modèle BIM virtuel dans le JN. Ainsi, le JN devient un outil précis et à jour représentant le système physique qui reflète également le contexte opérationnel de son jumeau physique. Le JN peut suivre les performances et l'historique de maintenance de chaque composant physique jumelé au fil du temps, détecter et signaler les comportements anormaux et recommander / planifier la maintenance (Afzalan et al., 2017).

Ainsi, avec l'avènement de l'Internet des objets (IoT), des Big Data géospatiaux et des algorithmes ML/DL en mode cloud la technologie JN est devenue rentable à mettre en œuvre

et est de plus en plus accepté dans les industries de construction de grandes infrastructures (Alonso et al., 2019). Un JN peut aider à relever les grands défis de la société civile, y compris la réalisation des objectifs de développement durable tout en tenant compte des problèmes d'urbanisation rapide, de la croissance démographique et de l'escalade des coûts d'infrastructure (Petty, 2017 ; Zeigler et al. 2018 ; Madni et al., 2019).

2.11 Le JN pour la ville ou City Digital Twins

Un JN urbain est une réplique virtuelle d'une ville, qui consisterait en la représentation numérique de réseaux urbains qui utiliseraient des données réelles obtenues à partir des dispositifs de surveillance pour informer de leur état en temps réel. Il ne fait aucun doute que les villes capables d'exploiter cette technologie et d'en tirer parti seront celles qui prospéreront. Outre le succès technologique, ils deviendront plus durables sur le plan environnemental, économique et social. Ce concept de JN pour la ville est né avec la représentation virtuelle d'objets spécifiques tels que les éoliennes, dans lesquels un modèle virtuel basé sur l'éolienne physique est développé afin d'optimiser ses performances et sa rentabilité. Un JN pour la ville sert à créer des stratégies de prévention et de surveillance de l'état de santé des infrastructures existantes de la ville ou de concevoir de nouvelles infrastructures. Cela est parfaitement lié aux événements météorologiques dus au changement climatique tel que les inondations urbaines car les données mesurées en temps réel d'une ville pourraient alimenter le modèle virtuel pour analyser les impacts d'un tel événement météorologique et donc élaborer un plan d'action corrective du point de vue de l'urbaniste. La capacité à réagir rapidement et à se remettre des événements inattendus dans une ville est essentielle pour accroître la résilience. Par exemple, en plaçant des capteurs IoT dans le réseau de transport, en cas d'événement d'urgence, un urbaniste peut être alimenté avec ces informations en temps réel afin de réacheminer les chemins affectés (Serrano, 2018).

Le développement des JN des villes permet définitivement de réduire l'écart entre réalité et vie virtuelle et il sera essentiel de responsabiliser les villes. Cependant, pour réaliser ces JN de ville, il faut développer quatre axes piliers :

- 1- Avoir un BIM d'un niveau de précision LOD 300 ou LOD 400 surtout pour les principaux infrastructures et bâtiments de la ville.
- 2- Avoir un SIG-3D ou un CIM d'un niveau de précision LOD 3 ou LOD 4 pour tous les espaces publics et les autres bâtiments de la ville.
- 3- Intégrer BIM et le SIG pour avoir une continuité dans la visualisation et l'analyse à des niveaux de précision très détaillés.
- 4- Connecté le JN à son double jumeau réel de la ville grâce à des appareils et capteurs IoT.

2.12 Intégration SIG-BIM pour les JN de la ville

Dans ce paragraphe, nous présentons l'intérêt principal de l'intégration SIG-BIM et une analyse détaillée de cette intégration, en effet cette intégration représente la pierre angulaire pour le développement des modèles de ville 3D ou JN de la ville (City Digital Twins). Nous débutons par un rappel de l'intérêt du SIG et BIM pour la ville. Puis, nous passons à l'importance dans ce flux de travail des techniques du scan au BIM pour l'automatisation de la création du BIM pour la ville. Enfin, nous détaillons le processus d'intégration des SIG et du BIM.

Liu et al. (Liu et al., 2017) a mené une étude interne sur les réalisations de l'intégration du BIM et du SIG. Dans cette étude, l'intégration est classée en trois catégories : niveau de données, niveau de processus et niveau d'application. Une comparaison de l'efficacité, de l'extensibilité, de l'effort et de la flexibilité des différentes solutions d'intégration a été ensuite effectuée.

L'intégration du BIM et du SIG peut se faire soit en créant de nouvelles normes ou de nouveaux modèles, soit en convertissant les données et en étendant les normes existantes. Une méthode courante consiste à convertir les données IFC en CityGML ou en un modèle CityGML étendu si des informations sémantiques supplémentaires provenant d'IFC sont ajoutées. L'accent est

souvent mis sur la conversion de la géométrie, qui peut être complexe (Donkers et al, 2016; Donkers, 2013). La transformation des coordonnées pourrait également être un problème car ce type d'informations fait souvent défaut à l'IFC. La conversion peut être implémentée comme un processus ETL (Extract, Transform, Load) un principe dérivé de l'informatique, qui représente une procédure de copie de données d'une ou plusieurs sources dans un système de destination qui représente les données différemment de la source. Et ici des logiciels commerciaux tels que FME, IFCExplorer, ArcGIS et Oracle Spatial peuvent être utilisés.

L'intégration au niveau du processus peut se faire à l'aide de technologies Web sémantiques telles que les ontologies de référence. Une ontologie de référence peut contenir les concepts de l'IFC et de CityGML et est capable de stocker leurs différences, et par cela elle peut faire partie du développement d'un système d'intégration transparent.

Les ontologies sont flexibles, mais leur inconvénient est qu'il est coûteux de les développer et qu'elles ne conviennent souvent que dans un domaine spécifique. Une autre méthode d'intégration au niveau du processus consiste à utiliser des services. Ici, le serveur de fonctionnalités Web OGC (WFS) et le WFS transactionnel (Web Feature Service) appliqué au BIM ont été utilisés pour servir les fonctionnalités d'IFC et CityGML. Cette méthode est efficace pour la conversion sémantique et géométrique et la perte d'informations est faible, mais cette solution est statique et implique le développement de systèmes (Liu et al., 2017).

2.13 Conclusion

La convergence des technologies JN, la 3D, le BIM, le SIG, l'IoT, le Big Data géospatial et l'utilisation des algorithmes de ML/DL pour les traitements de ces données dans un environnement cloud vont automatiser et améliorer davantage les flux de travail numériques et changer la façon actuelle de travail. Cette émergence accélère encore la portée et la contribution mondiales du géospatiale. Dans le temps à venir, nous allons voir une accélération de cette convergence des technologies géospatiales, l'IoT avec l'IA et ses sous-ensembles, à savoir les

machines d'apprentissage (ML) et l'apprentissage profond (DL) autour d'un développement de plateformes JN pour optimiser la prise de décision et anticiper sur les problématiques environnementales et patrimoniales. De cette façon, nous assistons à des scénarios où les JN aide à la transformation des technologies géospatiales et, d'autre part, les technologies géospatiales aident également à l'émergence de la technologie JN et d'autres technologies futures. Bien que cette transformation n'ait pas encore atteint sa pleine maturité, il devient important pour les parties prenantes du géospatiale de commencer à discuter de cet impact et de la manière dont nous visons l'avenir. Alors que l'utilisation du géospatial dans les secteurs traditionnels continue d'augmenter, l'avenir du marché géospatial réside dans les technologies d'automatisation et de prise de décision en temps réel sous l'environnement des JN.

Partie 1 : Conclusion

La convergence des technologies JN, la 3D, le BIM, le SIG, le Big Data géospatial et l'utilisation des algorithmes de ML/DL pour les traitements de ces données dans un environnement cloud vont automatiser et améliorer d'avantage les flux de travaux numériques et changer la façon actuelle de travail. Cette émergence accélère encore la portée et la contribution mondiales du géospatiale. Dans les temps à venir, nous allons voir une accélération de cette convergence des technologies géospatiales, de la 3D avec l'IA et ses sous-ensembles, à savoir les machines d'apprentissage (ML) et l'apprentissage profond (DL) autour d'un développement de plateformes JN pour optimiser la prise de décision en temps réel et anticiper sur les problématiques environnementales et patrimoniales. De cette façon, nous assistons à des scénarios où les JN aide à la transformation des technologies géospatiales et, d'autre part, les technologies géospatiales aident également à l'émergence de la technologie JN et d'autres technologies futures. Bien que cette transformation n'ait pas encore atteint sa pleine maturité, il devient important pour les parties prenantes du géospatiale de commencer à discuter de cet impact et de la manière dont nous visons l'avenir. Alors que l'utilisation du géospatial dans les secteurs traditionnels continue d'augmenter, l'avenir du marché géospatial réside dans les technologies d'automatisation et de prise de décision en temps réel sous l'environnement des JN.

PARTIE 2 : Étude de Cas

Partie 2 : Introduction

Avec la démocratisation des instruments de capture de la réalité, beaucoup de services commencent à adopter une approche de transformation digitale notamment en utilisant les données tridimensionnelles (3D) de l'environnement physique. Avec pour intérêt, par exemple la navigation sur des carrefours fréquentés pour tester les voitures autonomes, ou pour réaliser des travaux d'archéologues qui archivent des sites historiques de manière précise et détaillée, ou pour le besoin d'un planificateur d'infrastructure qui souhaite concevoir un projet routier avant travaux. De nombreuses applications s'appuient sur des données tridimensionnelles (3D). Une méthode populaire pour acquérir ces données est le balayage par scanner laser, qui les acquiert sous forme de nuages de points. En général, ces nuages de points représentent la surface extérieure des objets de la scène et le représente sous forme de coordonnées en X, Y et Z en plus de leur valeurs colorimétriques dans certain cas, et qui sont projetés dans un système relatif, local ou géoréférencé. Ces points dans le nuage manquent d'informations sur l'objet auquel ils appartiennent. Le processus pour ajouter cette information manquante à chaque point s'appelle la classification. La classification du nuage de points peut être automatisée à l'aide d'un algorithme informatique qui détermine le type d'objet en fonction de ces caractéristiques spatiales. Les propriétés d'un point, les statistiques sur le voisinage de ce point sont toutes des caractéristiques. Par exemple, la hauteur ou la valeur Z d'un point peut être utilisée pour distinguer des points faisant partie de la surface du sol de celle du haut des arbres ou des immeubles. Les algorithmes de classification se basent soit sur le traitement des nuages de points ou bien ils se basent sur l'utilisation de modèles. Le modèle détermine l'étiquette de classe à laquelle appartient un point. Ce modèle peut être basé sur des règles prédéfinies ou bien entraîné par un apprentissage sur des exemples de données. Les modèles traditionnels sont souvent basés sur des règles, ils reposent sur des règles conçues manuellement qui distinguent des points en fonction de leurs caractéristiques. Les premiers algorithmes d'apprentissage

étaient également basés sur des fonctionnalités conçues manuellement. Les règles et les fonctionnalités conçues manuellement impliquent des connaissances sur le domaine d'applications et les performances des modèles résultants dépendent de celui-ci. Plus récemment, les modèles d'apprentissage Machine supervisés non paramétriques sont utilisés pour résoudre les problèmes de classification. Surtout dans la classification des images, ces modèles atteignent une précision de pointe. Au lieu d'ingénierie manuelle, les modèles apprennent des fonctionnalités abstraites directement à partir d'exemples, appelés données d'apprentissage. Dans un troisième chapitre, nous développons une technique collaborative basée sur un algorithme de ML qui combine des données spatiales multi-capteurs pour surveiller et suivre les zones humides après un événement de crue éclair (flash-flood) dans une région aride saharienne du Maroc. Pour extraire les informations les plus efficaces, sept images satellites (radar et optique) prises avant et après l'évènement ont été utilisées. Le quatrième chapitre, est une application d'algorithme de ML dans un environnement nuage (cloud) en utilisant la plateforme Google Earth Engine (GEE) pour (1) suivre les changements de salinité des cavités d'eau permanentes qui se trouve dans la zone de Sebkhah d'Imlili, (2) surveiller les conditions humides / sèches de ces cavités, (3) évaluer la capacité du cloud computing à traiter plusieurs types de données, y compris les indices spectraux ou polarimétriques sur les données multicapteurs et l'imagerie multitemporelle, et (4) analyser la fonction du système aquifère de cette Sebkhah en examinant un réseau hydrographique souterrain et cartographier à l'aide d'algorithme d'IA pour détecter l'emplacement des cavités d'eau salée avec une précision nettement supérieure par rapport à ce qui peut être atteint en utilisant les données gratuites disponibles sur la plateforme GEE.

Le cinquième chapitre est une proposition d'un flux de travail utilisant la technologie Jumeau Numérique qui intègre les données laser nuage de point 3D, les données issues de capteurs IoT avec des algorithmes de ML pour la surveillance et la maintenance de l'état de santé du pont à haubon Mohammed VI de Rabat. Enfin, Le sixième chapitre est une discussion générale des résultats obtenus dans ces trois cas d'études.

Chapitre 3 : Approche collaborative de détection des changements sur l'imagerie spatiale multi-capteurs pour la surveillance des zones humides désertiques après une crue éclair dans le sud du Maroc

3.1 Introduction

Les crues éclair entraînent une augmentation rapide du niveau d'eau dans un ruisseau. Elles peuvent causer de graves dommages en quelques heures (p. Ex. Rupture d'un remblai, rupture d'un barrage). L'intensité peut augmenter considérablement, en particulier dans les cas où des précipitations intenses entraînent une montée rapide des eaux de crue montantes. Un plus grand volume de ruissellement peut résulter de diverses circonstances, telles qu'un pourcentage plus élevé de surfaces imperméables, de sols compactés, des conditions d'humidité du sol, du type et de la profondeur du sol, de la pente du terrain, de l'occupation ou l'utilisation des sols et de la végétation, ce qui peut entraîner de courts délais entre la pluviométrie et le débit de pointe (Javelle et al., 2014; Psomiadis, 2017; Bannari et al., 2016a; Bannari et al., 2016b). Les pluies violentes entraînent une érosion qui peut être localement catastrophique. Des traces de cette érosion hydrique sous forme d'incisions, de ravins et de dépôts de sédiments peuvent être mesurées par imagerie avec une très haute résolution spatiale (Oleire-Oltmanns et al, 2012).

Ces évènements extrêmes ont tendance à se produire à de très petites échelles spatiales et temporelles (affectant généralement des zones allant jusqu'à quelques centaines de kilomètres carrés, d'une durée de quelques minutes à quelques heures, évoluant très rapidement et donc difficiles à prévoir) (Javelle et al., 2014; Bannari et al., 2016b). Ce sont là quelques difficultés rencontrées lors de l'observation et de la prédiction à l'échelle régionale, notamment en raison de l'absence de réseaux hydrométriques dans l'environnement désertique. Les techniques de télédétection peuvent être d'une grande aide en fournissant des outils surs et économiques pour la surveillance, la cartographie et l'évaluation des transformations et des dommages causés par les évènements de crue éclair (Psomiadis, 2017; Bannari et al., 2016b). Pendant la saison des pluies, de fortes pluies provoquent chaque année des inondations au Maroc ; il s'agit notamment des crues éclair, des crues des rivières et des crues de boue (Psomiadis, 2017; Bannari et al., 2016a). En octobre 2016, une pluie torrentielle a provoqué une inondation fluviale impressionnante dans une grande partie du sud du Maroc, en particulier dans la ville de Laayoune et ses régions, situées au Sahara marocain. L'évènement a duré environ 10 h (entre le 28 et le 29 octobre). De plus, le barrage Sakia El Hamra, dont la capacité de stockage ne dépasse pas 112,6 Mm³, a connu une augmentation de volume de 7 à 203 mm³ lors de la crue éclair. Le pic de la crue a atteint plus de 3000 m³ / s, ce qui est bien au-dessus du seuil de la capacité dimensionnelle du déversoir (410 m³ / s), sur la base des informations obtenues de l'Agence des bassins versants de Sakia El Hamra et Oued Eddahab. Le passage de cette inondation exceptionnelle a provoqué le débordement des eaux de l'oued sur la crête du barrage de Sakia El Hamra, entraînant la dégradation de « la pente aval » et l'ouverture de deux brèches d'une centaine de mètres dans le corps du barrage au niveau du lit mineur de l'Oued. La hauteur des deux brèches a été considérablement augmentée à mesure que le déversement approchait et atteignait presque le niveau de l'oued (fig. 22).



Figure 22. Barrage de Sakia El Hamra à gauche (septembre 2016), la crue éclair entraînant l'ouverture de deux brèches de 100 m dans le corps du remblai au niveau du lit mineur de l'Oued (représenté par des cercles à droite-image de la main, prise en décembre 2016)

Le but de cette étude est de cartographier les changements dynamiques et d'estimer la dynamique de l'étendue des inondations avec des conditions d'eau et de sols humides / secs distribués dans l'espace et dans le temps lors d'un événement de crue éclair à l'échelle locale en utilisant une collaboration entre deux approches : l'une basée sur le traitement spectral et l'autre basé sur un traitement catégorique. La première étape a consisté à extraire quatre indices spectraux puis à détecter les changements dans les images diachroniques multispectrales à partir de trois images Sentinel-2 MSI (instrument Multispectral) et de deux images Landsat-8 OLI (Operational Land Imager) acquises avant et après l'évènement. La deuxième étape a été réalisée à l'aide de techniques de classification de modèles, à savoir des classificateurs machine d'apprentissage automatique non paramétriques basés sur des machines à vecteurs de support (SVM) avec des noyaux gaussiens (Kalantar et al., 2018; Abedi et al., 2012; Chang et Lin, 2011). Dans la première approche, nous avons déterminé l'étendue de la crue éclair en utilisant les changements de surface temporels et spatiaux des zones inondées en fonction des indices spectraux de l'eau et du sol humide / sec. Les meilleurs indices de discrimination ont été

sélectionnés parmi les quatre indices spectraux, et l'amplitude et l'orientation du vecteur de changement ont été calculées et reclassées pour extraire l'étendue de l'inondation de l'acquisition d'image de chaque point dans le temps et l'humidité et la sécheresse du sol dans ces zones. Dans la littérature, le suivi des changements dans la réponse des rivières et des zones humides aux crues éclair dans un environnement désertique est un travail très rare. Notre motivation pour cette étude est que cette recherche représente une chance d'étudier : (1) la réponse de cet écosystème désertique à l'effet de cet événement très bref et rare (2) connaître le temps de retour à l'état initial en utilisant des données spatiales. C'est pour ces raisons que les images satellites de différents capteurs ont été sélectionnées pour la cartographie des crues éclair. Il faut reconnaître que les images acquises peuvent avoir été prises plus d'un jour après le pic de crue. Cela peut influencer l'état du sol, le rendant entièrement différent de la situation d'inondation.

3.2 Matériel et méthodes

Dans la première partie de cette section, nous présentons la zone d'étude et une explication détaillée de l'ensemble de données et de l'étape de prétraitement. Enfin, nous utilisons un organigramme pour illustrer la méthodologie d'application des données radar optiques et synthétiques à ouverture (SAR).

3.2.1 Zone d'étude

Laayoune représente la plus grande ville du sud du Maroc (fig. 23). Cette zone est située entre les latitudes 27.00; 27,25 et longitudes -12,92; -13,38. La ville de Laayoune est délimitée à l'ouest par l'océan Atlantique Nord et est proche du bassin de Saquia El Hamra, qui fait partie de l'unité géologique de Tarfaya – Laayoune – Boujdour (fig. 23). Oued Saquia El Hamra occupe la partie centrale du Sahara avec une large ouverture sur l'océan Atlantique. Sa superficie est de plus de 142 865 km². Pendant la saison des pluies, l'agriculture sédentaire est

basée sur des sources d'eau souterraines et des lits de rivière à inondation sèche. Il est bien connu que les crues éclair sont imprévisibles et rares dans le désert du Sahara (Reid et al., 2004). Les précipitations représentent la variable la plus aléatoire parmi les mesures météorologiques dans les régions arides (Warner, 2004). En conséquence, la fréquence et la gravité des crues soudaines du désert varient chaque année et ne sont pas documentées (Reid et Frostick, 1997). Les précipitations dans le désert varient plus dans l'espace et sont plus aléatoires que les précipitations dans les régions humides, elles sont donc souvent décrites comme irrégulières. La réponse du système hydrologique de surface aux précipitations du désert est complexe; ainsi, la modélisation hydrologique est exclue (Dolman et al., 1997). Warner (Warner, 2004) a fait valoir que la plupart des inondations dans le désert se produisent en raison de la nature inhabituelle de la surface plutôt que des précipitations, car il est peu probable que ces dernières soient beaucoup plus intenses qu'un type de tempête similaire dans les zones plus humides. Les raisons en sont multiples (Warner, 2004, Reid et Frostick, 1997; Tanner et al., 2016). (i) De très rares matières organiques sont présentes dans le sol pour absorber les précipitations. (ii) La plupart des zones désertiques sont géologiquement dominées par des roches imperméables, qui ont un fort potentiel de ruissellement, dans toutes les zones du bassin de drainage. Par conséquent, si une quantité anormale de pluie se produit en très peu de temps, elle s'accumule rapidement dans l'eau qui coule dans les ruisseaux et les rivières dans les zones inondables. (iii) La rareté de la végétation implique que la goutte de pluie peut sceller la surface du sol. (iv) Il y a un manque de faune, comme les animaux, les insectes et les vers, qui rendent le sol relativement perméable. (v) La formation du ruissellement est fortement influencée par l'état structurel de la surface. La structure du sol de surface est dégradée par les précipitations, ce qui entraîne la formation de croûtes qui favorisent le ruissellement.




Figure 23. Zone d'étude.

Les dunes de Laayoune sont considérées comme les plus rapides du monde, avec une vitesse moyenne d'environ 32 m/an, notamment pour les dunes d'une hauteur de plus de neuf mètres (Sharratt et al., 2007; Elbelrhiti et al., 2005). De plus, dans la zone d'étude, il existe deux zones de Sebkhia, qui représentent des dépressions humides avec une surface saline dans des environnements désertiques (Fig.23). Ils sont généralement considérés comme des zones humides inondables de grand intérêt environnemental, et ils sont fortement liés à de nombreux problèmes environnementaux, tels que le changement climatique, la qualité de l'eau, l'habitat faunique et la biodiversité (Evans et al., 1964). Les Sebkhias sont supratidaux, se formant le long des côtes arides, et sont caractérisés par des dépôts de carbonate évaporé avec un peu de siliciclastique. Ils forment également des séquences subaériennes, de programmation et de haut-fond qui ont une épaisseur moyenne d'un mètre ou moins. De plus, les Sebkhias sont composés de plus de poches de cavités d'eau permanentes et de sel dans le désert, où les

précipitations sont connues pour être rares (Evans et al., 1964; Essefi et al., 2015; Marquer et al., 2008).

3.2.2 Matériaux

Notre méthodologie est principalement basée sur la détermination de la taille de la zone directement affectée par les eaux de crue et la démonstration de la façon dont la combinaison de capteurs optiques MSI et OLI et de données radar peut contribuer à une connaissance plus approfondie de la zone considérée. Les données ont été traitées pour révéler et délimiter les zones inondées. La plateforme d'application Sentinel (SNAP), le système d'analyses géoscientifiques automatisées (SAGA), le système de soutien à l'analyse des ressources géographiques (GRASS) et Quantum GIS (QGIS), qui ont une architecture commune open source pour les boîtes à outils de SIG et de traitement d'image, ont été utilisés pour l'exploitation des données d'observation de la Terre (OT). Les deux types d'images optiques ont été acquis sur le Web à l'adresse <https://glovis.usgs.gov/> ; Les données radar ont été obtenues à partir de <https://scihub.esa.int/>.

3.2.3 Jeu de données et prétraitement

L'ensemble de données utilisé dans la présente recherche comprend des images spatiales (tableau. 6), notamment :

Tableau 6 Ensembles de données utilisés dans cette étude.

Satellite	Instrument	Mode/Path-Row	Date d' Acquisition	Utilisation
Sentinel 2 A	MSI	L1C TC SGS	13/10/2016	Deux semaines avant l'évènement de crue éclair utilisé pour

				calculer l'image de référence
Landsat 8	OLI	LC (105-41)	28/09/2016	Un mois avant la crue éclair utilisée pour calculer l'image de référence
Sentinel 2 A	MSI	L1C TL SGS	30/10/2016	Un jour après l'événement de crue éclair utilisé pour la cartographie de l'étendue des crues
Landsat 8	OLI	LC (205-41)	13/11/2016	Deux semaines après une crue éclair utilisée pour l'extraction d'informations sur l'eau et l'humidité / la sécheresse du sol
Sentinel 2 A	MSI	L1C TL SGS	01/01/2017	Deux mois après une crue éclair utilisée pour l'information sur l'eau et l'humidité / la sécheresse du sol
Sentinel 1 A	C-SAR	IW GRDH 1SDV (VV, VH)	21/10/2016	Une semaine avant la crue éclair
Sentinel 1 B	C-SAR	IW GRDH 1SDV (VV,VH)	02/11/2016	Trois jours après l'évènement de crue éclair

Trois images Sentinel-2 MSI, une avant et deux après l'évènement de crue éclair, ont été utilisées pour extraire les indices spectraux ;

Deux images Landsat-8 OLI (path 205, row 41), une avant et une après l'évènement de crue éclair, ont été utilisées pour extraire les indices spectraux ;

Deux images SAR Sentinel-1 (S1), une avant et une après l'évènement de crue éclair, ont été utilisées pour le co-enregistrement et la classification afin d'extraire la zone d'inondation.

Les bandes dans la plage spectrale de réflectance solaire ont été utilisées pour extraire les zones urbaines, la végétation, l'eau et les sols humides / secs. Ensuite, les bandes numériques d'origine, OLI et MSI, ont été converties en une valeur de réflectance spectrale minimale au satellite et une réflectance au satellite, puis converties en réflectance de surface (Flood, 2014; Richards, 1993; Teillet, 1992; Nguemhe Fils et al., 2019). Toutes ces données (fig. 24) ont été géoréférencées au système de coordonnées WGS-84 et au système de coordonnées Universal Transverse Mercator de la zone 28N. Chaque jeu de données OLI / MSI a été découpé pour refléter l'étendue de l'étude.




Figure 24. Séquence d'inondation. (a) Image de référence = Moyenne de MSI et OLI avant inondation. (b) Sentinel-2 MSI un jour après une crue éclair. (c) Sentinel-1A trois jours après une crue soudaine. (D) Landsat-8 OLI deux semaines après les inondations.

Le traitement préliminaire du capteur OLI a fait l'objet d'une caractérisation radiométrique et spectrale importante. L'étalonnage représente une conversion en réflectivité et en rayonnement des nombres numériques selon l'équation (1) pour la réflectance L8 OLI en haut de l'atmosphère (Top-of-Atmosphere TOA) et l'équation (2) pour la réflectance S2A MSI TOA pour chaque bande en fonction des métadonnées des images (Flood, 2014):

$$\rho_{\lambda} = \frac{M_{\rho} \times Q_{cat} \times A_{\rho}}{\sin \theta} \quad (1)$$

où

ρ_λ = Réflectance TOA,

M_p = facteur d'échelle multiplicatif de réflectance pour la bande (obtenu à partir du fichier de métadonnées),

A_p = facteur d'échelle additif de réflectance pour la bande (obtenu à partir du fichier de métadonnées),

Q_{cal} = valeur de niveau du pixel en Compte numérique (DN),

θ = Angle d'élévation solaire (à partir du fichier de métadonnées).

$$\rho_\lambda = (float)\left(\frac{Q_{cal}}{QUANTIFICATION_{VALUE}}\right) \quad (2)$$

Q_{cal} = valeur de pixel LIC en DN,

$QUANTIFICATION_{VALUE}$ est fourni dans le fichier de métadonnées.

Les images multitemporelles devaient être corrigées radiométriquement avant d'être réutilisées dans cette étude. Cela impliquait de normaliser le changement de la valeur de luminosité (DN) car les conditions atmosphériques variables et la position du soleil provoquent une variation de l'éclairage. La normalisation radiométrique a été effectuée sur la base de caractéristiques pseudo-invariantes (PIFs) dans les images, qui sont des objets bien définis spatialement et stables spectralement et radiométriquement. (Les valeurs moyennes de DN de référence des scénarios pré-inondation, c'est-à-dire la moyenne de l'OLI le 28 septembre 2016 et du MSI le 13 octobre 2016, ont été sélectionnées comme références ou images de base pour la normalisation radiométrique des trois autres images post-inondation (MSI sur 30 octobre 2016, OLI le 13 novembre 2016 et MSI le 1er janvier 2017). Pour les objets ayant la même réflectivité sur les deux dates, les comptages numériques sur chaque date sont de simples fonctions linéaires des mêmes variables et, par conséquent, sont des fonctions linéaires les unes des autres. L'équation (3) a été utilisée pour la normalisation radiométrique (Schott et al., 2008).

$$DN_{1i} = \frac{\sigma_{1i}}{\sigma_{2i}} DN_{2i} + (\mu_{1i} - \frac{\sigma_{1i}}{\sigma_{2i}} \mu_{2i}) \quad (3)$$

où

DN_{1i} = Valeur en pixels à partir de la date 1 *,

DN_{2i} = valeur en pixels à partir de la date 2 **,

σ_{1i} = écart type (SD) de PIF à partir de la date 1 *,

σ_{2i} = écart type (SD) du PIF à partir de la date 2 **,

μ_{1i} = Moyenne de PIF à partir de la date 1 *,

μ_{2i} = moyenne du PIF à partir de la date 2 **,

i = numéro de bande (2,3,4,5,6,7) pour OLI et (2,3,4,8A, 11,12) pour MSI,

1 * = moyenne de l'OLI et du MSI avant inondation (image de référence),

2 ** = Image après inondation.

La moyenne et l'écart type (SD) des PIF de chaque bande d'images à deux dates ont été récupérés à titre d'exemple ; ces valeurs ont été utilisées avec la formule ci-dessus, résultant en une normalisation radiométrique bande à bande (tableau. 7).

Tableau 7 Écart moyen et standard des ensembles de données satellitaires Sentinel-2 et Landsat-8 avant et après normalisation.

	Canal avant normalisation		Canal après normalisation	
	Moyenne	SD	Moyenne	SD
Référence avant inondation 1	1956.47	95.21	2050.66	105.14
Référence avant inondation 2	2364.15	145.78	2390.44	155.55
Référence avant inondation 3	3291.65	237.01	3335.65	255.66

Référence avant inondation 4	4050.43	224.13	4066.77	234.66
Référence avant inondation 5	4676.46	288.21	4705.33	299.77
Référence avant inondation 6	3558.22	275.94	3588.88	285.98
MSI un jour après inondation 2	1949.74	92.74	1966.65	100.79
MSI un jour après inondation 3	2358.06	141.98	2377.09	156.88
MSI un jour après inondation 4	3286.00	231.30	3289.88	244.54
MSI un jour après inondation8A	4034.24	218.96	4055.51	277.77
MSI un jour après inondation 11	4655.17	266.52	4675.66	288.76
MSI un jour après inondation 12	3543.82	258.24	3588.74	278.62

3.2.4 Méthodologie

Les données spatiales optiques permettent la détection des changements à l'aide de plusieurs méthodes, allant des procédures classiques de photo-interprétation visuelle aux méthodes semi-automatisées et automatisées basées sur les caractéristiques spectrales. Le succès de la détection des modifications dépend des procédures de traitement et de classification des images utilisées (Wang, 2004; Gianinetto et al., 2006; Schmid et al., 2005; Martinis, 2017; Martinis et al., 2018; Chignell et al., 2015; Lacava et al., 2010; Richter et al., 2003; Bryant et Gilvear, 1999). Pour les caractériser, les capteurs optiques utilisent les propriétés d'émission et de réflexion des matériaux. Les images optiques sont basées sur des fonctionnalités et permettent une interprétation fluide. En outre, un nombre important de capteurs optiques ont été utilisés pendant des décennies pour cartographier avec succès les inondations, car les capteurs optiques peuvent détecter les inondations depuis l'espace en utilisant les caractéristiques spectrales uniques de l'eau (Gianinetto et al., 2006; Chignell et al., 2015). Bien qu'un environnement de zone humide désertique présente une multiplicité de caractéristiques spectralement similaires,

les bandes proche infrarouge montrent des distinctions claires entre ces types de couverture terrestre (Schmid et al., 2005). Dans les zones humides inondées, les eaux libres et la végétation inondée absorbent généralement le rayonnement proche infrarouge et sont représentées dans les images optiques par de faibles valeurs DN, tandis que les classes non inondées émettent un rayonnement infrarouge et sont représentées par des valeurs DN plus élevées (Gianinetto et al., 2006; Schmid et al., 2005).

L'utilisation du traitement spectral pour acquérir des indices nécessite l'analyse des caractéristiques spectrales des images de télédétection afin de déterminer leur relation quantitative avec l'humidité / l'eau et la sécheresse dans les changements de terrain. L'albédo, l'indice de différence d'eau normalisé (NDWI), l'indice de sécheresse multibande normalisé (NMDI) et l'indice d'humidité de différence normalisée (NDMI) sont les principaux indices spectraux utilisés pour caractériser l'humidité dans les changements spectraux de terrain (Bannari et al., 2016a; Bannari et al., 2016b ; Jackson, 1997). Le traitement hydrologique consiste à acquérir des indices pour analyser les caractéristiques hydrologiques d'un modèle numérique d'élévation (MNT) afin de détecter les zones associées aux crues éclair et à l'érosion causées par les tempêtes de pluie et le transport et l'accumulation de sédiments (Bannari et al., 2016b; Gianinetto et al., 2006). Cependant, même avec l'augmentation du nombre de systèmes de satellites et de capteurs acquérant des données avec des caractéristiques spectrales, spatiales, radiométriques et temporelles améliorées, la plupart des ensembles de données sur la couverture terrestre existants ont été dérivés d'un traitement catégorique basé sur des approches pixel ou objet utilisant une reconnaissance de modèle conventionnelle ou avancée. techniques, telles que les forêts aléatoires (RF) (Feng et al., 2015; Shi et Yang, 2016), les réseaux de neurones (NN) (Kalantar et al., 2018; Foody et al., 1995; Foschi et Smith, 1997; Campolo et al., 2003; Foody, 2004; Kim et Barros, 2001; Kavzoglu et Mather, 2003; Hsu et al., 1997; Imrie et al., 2000) et les machines à vecteurs de support (SVM) (Kalantar et al., 2018; Abedi et al., 2012; Chang et Lin, 2011; Yang, 2011; Sachdeva et al., 2017; Shafizadeh-Moghadam et al., 2018; Tehrany et al., 2014). Il est évident que la collaboration de toutes ces méthodes de traitement peut améliorer la cartographie en utilisant les informations multispectrales,

multitemporelles et spatiales disponibles pour obtenir la meilleure caractérisation des changements de zones mouillées / humides et de terres sèches à partir d'images de télédétection après un événement d'inondation éclair (Zeng et al., 2006; Zongyi et al., 2011; Dobos, 2007; Irons et al., 1989; Xu, 2006; Feyisa et al., 2014).

Pour cartographier les zones inondées, différentes données et méthodologies de télédétection ont été utilisées conformément aux critères suivants: (I) données multi-capteurs (SAR, multispectral); (II) l'imagerie gratuite (à coût nul) (c'est-à-dire que nous n'avons utilisé que des données gratuites); (III) la disponibilité des données relatives à la phase d'inondation (pré-inondation, pendant-inondation et post-inondation); (IV) différentes résolutions spatiales des données SAR et optiques; et (V) la disponibilité des données auxiliaires (DEM ou autres données auxiliaires). Nous avons collecté (a) des données multispectrales pré-inondation (OLI et MSI) acquises avant l'inondation et utilisé leur moyenne comme référence pour l'analyse de détection des changements ; (b) les données pendant l'inondation, collectées après un jour de données sur les inondations maximales (MSI); c) des données post-inondation multidimensionnelles (optiques et SAR) (Notti et al., 2018).

3.2.4.1 Méthodologie des données multispectrales

Considérons deux images multispectrales acquises sur la même zone géographique à deux moments différents. Ils sont exprimés en T1 et T2. T1 est l'image de référence et a été obtenue en calculant la moyenne de deux images acquises avant l'évènement d'inondation à partir de capteurs OLI et MSI; T2 correspond à l'une des trois images multitemporelles acquises à différents moments après l'inondation des capteurs OLI et MSI. Ensuite, comme le montre la figure 25, la méthode collaborative spectrale et catégorique proposée comporte six étapes principales : (1) correction radiométrique et normalisation; (2) traitement spectral; (3) traitement catégorique; (4) détection de changement radiométrique; (5) détection de changement catégorique; et (6) la détection collaborative des changements.




Figure 25. La méthodologie collaborative spectrale et catégorique représentée sous forme de flux de travail.

Traitement spectral et choix de l'espace des caractéristiques à partir des indices calculés

L'albédo, l'indice de différence d'eau normalisé (NDWI), l'indice de sécheresse multibande normalisé (NMDI) et l'indice d'humidité de différence normalisée (NDMI) sont les principaux indices utilisés pour caractériser le changement d'humidité / sécheresse des terres (Zeng et al., 2006; Zongyi et al., 2011; Dobos, 2007; Irons et al., 1989; Xu, 2006; Feyisa et al., 2014; Notti et al., 2018; Lobell et Asner, 2002; Wang et Qu, 2007; Chen et al., 2014; Becerril-Pi et al., 2015). L'indice d'albédo (équations (4) et (5)) représente un paramètre physique qui est affecté par les conditions de surface du sol, comme l'humidité du sol, la couverture végétale, les eaux libres et les terrains secs. Par conséquent, l'albédo (« (4) » et « (5) ») peut être utilisé comme un paramètre physique important reflétant l'état humide / sec du terrain (Zeng et al., 2006; Zongyi et al., 2011; Dobos, 2007).

$$Al = (0.356\rho_b + 0.130\rho_r + 0.373\rho_{nir} + 0.085\rho_{SWIR-1} + 0.072\rho_{SWIR-2} - 0.0018) \quad (4)$$

où ρ_b : bande bleue (bande 2 pour OLI ou MSI), ρ_{nir} : bande proche infrarouge (bande 5 pour OLI ou bande 8A pour MSI), ρ_r : bande rouge (bande 4 pour OLI ou MSI), ρ_{swir-1} : bande swir-1 (infrarouge à ondes courtes 1) (bande 6 pour OLI ou bande 11 pour MSI), ρ_{swir-2} : bande swir-2 (infrarouge à ondes courtes 2) (bande 7 pour OLI ou bande 12 pour MSI).

Pour le processus de normalisation des données, nous devons d'abord trouver les valeurs maximales et minimales d'albédo dans la zone d'étude, puis utiliser ces valeurs pour normaliser les données et obtenir l'indice normalisé d'albédo.

$$Albedo_n = (Al - Al_{min}) / (Al_{max} - Al_{min}) \quad (4')$$

le NDWI (équations (6) et (7)) est également utilisé pour la cartographie de l'eau du sol après des périodes de crue éclair (Xu, 2006; Feyisa et al., 2014; Notti et al., 2018). Xu (Xu, 2006) a également conclu que le NDWI pouvait être utilisé pour détecter l'inondation des rizières en Chine.

$$NDWI = (\rho_b - \rho_{swir-1}) / (\rho_b + \rho_{swir-1}) \quad (5)$$

La normalisation de cet indice est la suivante:

$$NDWI_n = (NDWI - NDWI_{min}) / (NDWI_{max} - NDWI_{min}) \quad (5')$$

En outre, un nouvel indice de sécheresse, à savoir NMDI (équations (8) et (9)), a été proposé (Wang et Qu, 2007) en utilisant trois bandes dans le proche infrarouge (NIR) et l'infrarouge à ondes courtes (SWIR) pour la télédétection du sol et de la teneur en eau du sol (0,86 μm , 1,64 μm et 2,13 μm):

$$NMDI = 700 (\rho_{nir} - \rho_{swir-1} + \rho_{swir-2}) / (\rho_{nir} + \rho_{swir-1} - \rho_{swir-2}) \quad (6)$$

$$NMDI_n = (NMDI - NMDI_{min}) / (NMDI_{max} - NMDI_{min}) \quad (6')$$

Le NMDI (équations (10) et (11)) est un indice des données de réflectance de surface (Chen et al., 2014; Becerril-Pi et al., 2015) qui utilise les six bandes, et les coefficients sont déterminés

empiriquement comme ceux qui transforment un ensemble de pixels d'apprentissage en nouvelles dimensions alignées avec une variabilité maximale.

$$NDMI = (\rho_{nir} - \rho_{swir-1}) / (\rho_{nir} + \rho_{swir-1}) \quad (7)$$

L'indice normalisé est:

$$NDWI_n = (NDWI - NDWI_{min}) / (NDWI_{max} - NDWI_{min}) \quad (7')$$

Les images de tous les indices de l'eau, y compris NDWIn et NDMIn, contribuent certainement à améliorer la séparabilité des plans d'eau. La plupart des valeurs NDMIn des masses d'eau sont supérieures à 0,76, tandis que la plupart des valeurs NDWIn des masses d'eau sont supérieures à 0,5. Comme le montrent les figures 26 a, c, les valeurs NDWIn des zones bâties sont clairement différentes. Par rapport aux plans d'eau, la végétation a des valeurs NDWIn beaucoup plus faibles; ainsi, cet indice facilite la distinction entre la végétation et les plans d'eau.




Figure 26. Indices extraits de l'OLI deux semaines après l'inondation: (a) indice d'humidité à différence normalisée (NDMI), (b) albédo, (c) indice d'eau à différence normalisée (NDWI), et (d) sécheresse multibande normalisée indice (NMDI).

En effet, les caractéristiques accumulées dans l'image NDWIIn apparaissent dans un ton jaune clair avec des valeurs positives comprises entre zéro et 0,2. Cela entraîne une confusion, en particulier dans les zones urbaines, entre les zones bâties et le sol.

Après avoir calculé l'albédon, le NDWIIn, le NDMIIn et le NMDIIn (fig. 43), nous les avons empilés dans un fichier image et avons calculé la matrice de corrélation pour choisir les indices les moins corrélés, qui se sont avérés être le NDMI et l'albédo, dont la relation a un coefficient de corrélation de -0,486 (tableau. 8). Cette valeur a été confirmée dans l'espace des caractéristiques (NDMI, albédo). Ainsi, le NDMI et l'albédo ont été choisis comme espace des caractéristiques pour mieux extraire les changements dans cette zone.

Tableau 8 Matrice de corrélation.

	NDMI _n	Albedo _n	NDWI _n	NMDI _n
NDMI _n	1	-0,49	0,84	0,88
Albedo _n	-0,49	1	0,75	0,72
NDWI _n	0,84	0,75	1	0,97
NMDI _n	0,88	0,72	0,97	1

Comme décrit ci-dessus, l'analyse montre qu'il existe une corrélation significative entre le sol humide / sec, le NDMI et l'albédo. La figure 27 résume les différences d'albédo car l'humidité / la sécheresse du sol varie à différentes phases après les crues éclair. La figure 27 est basée sur l'espace des caractéristiques (Δ (NDMI), Δ (Albedo)).




Figure 27 Espace des caractéristiques (Δ (NDMI), Δ (albédo)).

La réduction de l'humidité du sol entraîne une augmentation significative de l'albédo et les modifications de l'albédo affectent l'équilibre des radiations de surface. Dans l'espace (Δ

(Albedo), Δ (NDMI)), l'albédo dépend non seulement de l'humidité du sol mais aussi de la température de surface du sol. La ligne reliant A et B sur la figure 28 est considérée comme une ligne d'albédo élevé et reflète la sécheresse et la valeur d'albédo élevée à la surface du sol, qui est la limite supérieure de l'albédo élevé, et correspond à une surface aride complète. La ligne reliant C et D est la ligne à faible albédo, ce qui représente une humidité suffisante du sol.

Pour étudier plus en détail la loi de distribution spatiale de l'évènement de crue éclair dans l'espace des caractéristiques (Δ (NDMI), Δ (Albedo)), nous présentons un nuage de points juste après l'évènement (fig. 28).




Figure 28. Diagramme de dispersion et courbe de régression linéaire de l'espace des caractéristiques (Δ (NDMI), Δ (Albedo)).

Après une analyse de régression statistique, nous constatons que Δ (Albedo) et Δ (NDMI) ont une corrélation linéaire négative significative, comme indiqué dans l'équation (8). L'équation de régression est:

$$\Delta(\text{Albedo}) = 230.426 - 1.035 \Delta(\text{NDMI}) \quad (8)$$

Le coefficient de corrélation est de -0,486. Cela indique que Δ (NDMI) et Δ (Albedo) ont une corrélation négative modérée: c'est-à-dire qu'ils ont un faible degré d'association, donc une tendance statistique croissante de la sécheresse du sol entraîne une tendance statistique progressivement décroissante dans NDMI, tandis que l'albédo a une tendance croissante. Dans l'espace des caractéristiques (Δ (NDMI), Δ (Albedo)), le sol humide / sec se reflète clairement. Selon l'étude de Verstraete et Pinty (Verstraete et Pinty, 1996), différents sols humides / secs peuvent être efficacement séparés en divisant l'espace caractéristique (Δ (NDMI), Δ (Albedo)) dans l'axe principal du nuage dans le sens de l'évolution des tendances. (Fig. 29).




Figure 29. La direction et l'ampleur du changement dans l'espace des caractéristiques (Δ (NDMI), Δ (Albedo)) en utilisant les positions d'un pixel dans l'image de référence à la date T1 et du même pixel à une date ultérieure T2 après l'évènement.

La méthode utilisée dans cette étude est basée sur l'analyse de la relation entre les indices spectraux du sol humide et du sol sec. L'idée de l'analyse vectorielle de changement (CVA) est que certains pixels avec des valeurs différentes persistent au fil du temps à des emplacements sensiblement différents dans l'espace des caractéristiques. Cependant, le meilleur espace

thématique discriminant est l'objectif déterminant (Jensen, 2000 ; Youssef et al., 2016 ; Chen et al., 2013). Les changements dans les terres humides et sèches entre les événements avant et après les crues éclair ont été déterminés à l'aide de l'CVA avec les indices NDMI et albédo. L'CVA est une technique multivariée (Jensen, 2000 ; Youssef et al., 2016 ; Chen et al., 2016b; Bayarjargal et al., 2006). Cela permet à l'analyse pixel par pixel de bandes ou de produits spectraux sur deux axes d'un plan cartésien d'évaluer les changements entre les positions des pixels (T1) dans l'image de référence et le même pixel (T2) dans l'image post-inondation (fig. 29). La magnitude (M) indique l'intensité du changement et est dérivée en utilisant la distance euclidienne dans l'équation (9). Le résultat est une image classée dans l'une des quatre catégories: faible (0–25), moyenne (25–50), élevée (50–75) et extrême (75–100), où les valeurs sont la somme des changements qui s'est produit entre les dates.

Le but de notre méthode est de trouver le meilleur espace bidimensionnel des caractéristiques qui peut le mieux distinguer les changements entre les terres humides et sèches. À cette fin, cette étude vise à trouver des indices de corrélation négatifs significatifs. Dans cet espace significatif de corrélation, nous calculons la magnitude et l'orientation du vecteur de changement (CV) comme suit (équations (9) et (10)):

$$M = \sqrt{(Albedo1 - Albedo2)^2 + (NDMI1 - NDMI2)^2} \quad (9)$$

où les sous-indices 1 et 2 représentent des images prises respectivement avant et après inondation.

La direction du changement représente le type de changement (θ) détecté dans un pixel correspondant à T1 et T2; c'est-à-dire que chaque vecteur est fonction de la combinaison des changements positifs et négatifs se produisant dans la bande spectrale ou les produits analysés, avec θ déterminé selon l'équation (14). L'image résultante comprend des valeurs comprises entre 90 et 180 °, représentant une augmentation de la sécheresse, ou entre 270 et 360 °, supportant des pixels lumineux indiquant une augmentation de l'humidité; les valeurs dans l'intervalle de 0 à 90 ° et 180 à 270 ° représentent des pixels n'illustrant aucun changement; par

conséquent, il n'y a aucune preuve décisive que la sécheresse ou l'humidité augmentera ou diminuera.

$$\theta = \tan^{-1} \frac{(NDMI1-NDMI2)}{(Albedo1-Albedo2)} \quad (10)$$

Traitement catégorique par classification machine d'apprentissage SVM.

L'apprentissage automatique induit des liens basés sur les informations contenues dans les données pour guider la formation d'un modèle de classification via la minimisation de la fonction erreur entre la réalité et le résultat du modèle de classification.

La SVM est une méthode de traitement catégorique paramétrique basée sur la réduction du problème de discrimination à celui de la recherche de l'hyperplan linéaire optimal (Kalantar et al., 2018; Abedi et al., 2012; Chang et Lin, 2011; Yang, 2011; Sachdeva et al., 2017; Shafizadeh-Moghadam et al., 2018; Tehrany et al., 2014). Deux idées ou conseils aident à atteindre cet objectif:

- Définir l'hyperplan comme une solution à un problème d'optimisation qui sépare les différentes classes de données sous contraintes dont la fonction objective est exprimée à l'aide de produits scalaires entre vecteurs et dans lesquelles le nombre de contraintes ou de points «actifs» se trouvant sur les frontières sont appelés vecteurs supports; le milieu de la marge est l'hyperplan de séparation optimal qui contrôle la complexité du modèle.

- La sélection du noyau est la tâche la plus importante dans l'implémentation et le succès du classificateur SVM (Shafizadeh-Moghadam et al., 2018; Tehrany et al., 2014). Une fonction de noyau ou astuce du noyau est introduite dans le produit scalaire pour rechercher implicitement des surfaces de séparation non linéaires, et la transformation non linéaire des données en un espace de caractéristiques plus grand est induite. Un hyperplan optimal est déterminé à l'aide de points de données d'apprentissage ou du vecteur de support de chaque classe sur l'hyperplan à maximiser, et sa capacité de généralisation est vérifiée à l'aide d'un point de données de validation. Les vecteurs d'apprentissage, x_i , sont projetés dans un espace

de dimension supérieure par la fonction du noyau. Le SVM avec l'astuce du noyau devient non paramétrique puisqu'elle peut fonctionner avec quelques points de données d'entraînement; c'est le cas dans cette étude, avec des classes comptant moins de 45 échantillons. La fonction de noyau utilisée dans cette expérience est une fonction de base radiale (RBF) - définie par l'équation (11) - pour deux vecteurs d'entrée, x_i et x_j , avec le paramètre de marge maximale γ , défini par l'utilisateur. Le choix du noyau RBF est justifié par l'utilisation fréquente de cette méthode dans la littérature dans le domaine de la classification d'images spatiales et dans les études de détection de changement (Yang, 2011; Sachdeva et al., 2017). Ce noyau ne nécessite qu'un seul paramètre à être prédéfini, ce qui le rend facile à implémenter contrairement aux autres noyaux.

$$K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2}, \gamma > 0 \quad (11)$$

3.2.4.2 Méthodologie des données radar SAR

La polarisation SAR est un facteur déterminant dans la détection des crues. Il a été prouvé dans plusieurs études précédentes que les images polarisées HH (horizontales / horizontales) sont plus appropriées pour la détection des inondations que les images polarisées VV (verticales / verticales) ou polarisées croisées (Clement et al., 2017 ; Matgen et al., 2011 ; Martinis, 2010 ; Gan et al., 2012 ; Ardiana et al., 2000 ; Martinez et Le Toan, 2007 ; Ormsby et al., 1985 ; Rao et al., 2006 ; Schumann et al., 2007 ; Vilches, 2013 ; Voigt et al., 2008). Ceci est principalement dû au fait que la polarisation HH donne la meilleure discrimination des valeurs de rétrodiffusion entre un sol sec et un sol humide et entre un sol lisse et un sol rugueux, ce qui permet une meilleure surveillance de la zone inondée après un évènement (Clement et al., 2017 ; Ormsby et al., 1985). Cependant, pour cette étude, l'image disponible pendant l'inondation a une polarisation VV et VH d'intensité. La polarisation VV a été jugée préférable, car l'angle d'incidence moyen des données rend cette image appropriée pour la surveillance des inondations et permet une détection efficace des zones humides. De plus, la même polarisation (VV) a été choisie pour les deux dates afin d'obtenir une co-registation pour comparer la même

co-polarisation (VV – VV). Cette stratégie donne de meilleurs résultats que l'utilisation de la polarisation croisée (VH – VV).

Le SAR à imagerie radar utilise la rugosité de surface cible et la représente dans les images. L'eau a une propriété diélectrique particulière, en particulier l'eau stagnante avec un réflecteur spéculaire; par conséquent, il renvoie un signal radar faible et affiche un signal de rétrodiffusion faible dans les images radar (Touzi et al., 2005 ; Barber et al., 1996).

La capacité de pénétrer la couverture nuageuse et de détecter l'eau fait du système SAR par satellite un outil puissant pour la surveillance des crues éclair, car les crues éclair sont souvent associées à de fortes pluies, et il est presque impossible pour les instruments de télédétection optique d'imager l'eau dans de telles circonstances. Le SAR a un grand potentiel en tant que source d'informations pertinentes et en temps quasi réel. Il représente une chance unique en raison de la mauvaise résolution temporelle des capteurs optiques, qui est extrêmement proche de l'acquisition en temps réel de cet événement très bref. C'est la raison pour laquelle les images satellites sont sélectionnées à partir de différents capteurs pour la cartographie des crues éclair: les images acquises ont été prises plus d'un jour après le pic de crue. Par conséquent, le SAR à longue longueur d'onde caractérise mieux les inondations des zones humides que le SAR à courte longueur d'onde (Toyra et Pietroniro, 2005 ; Pultz et al., 1997 ; Ramsey et al., 2013). Cependant, la disponibilité limitée des SAR à longue longueur d'onde est paradoxalement une réelle limitation à l'utilisation du SAR radar pour cartographier et surveiller les inondations dans les rivières et les zones humides (Barber et al., 1996). Enfin, il se pourrait bien qu'il y ait des limites à la fois pour les données radar et optiques. Cependant, travailler avec une approche collaborative peut aider à combiner les points forts de différents types de capteurs. Par exemple, les données avec une résolution spatiale élevée et un cycle de répétition faible peuvent être combinées avec des données qui ont une résolution spatiale faible avec une acquisition répétée élevée pour créer un produit d'inondation avec une résolution élevée et des observations fréquentes (Schumann et al., 2007 ; Vilches, 2013 ; Voigt et al., 2008). C'est l'association de données radar et optiques sans nuage qui permet de produire des cartes précises de la

surveillance des crues éclair et humides. Avec les résultats de chaque capteur, cela peut être fait en combinant le traitement spectral et catégorique dans un processus collaboratif de détection des changements. Cela fournit des informations complémentaires et augmente la précision de la surveillance. En raison de la nature dynamique rapide de cet événement, les résolutions temporelles et spatiales influencent également la précision de la cartographie des crues éclair, de sorte que des données satellite multitemporelles et multi-résolutions sont nécessaires pour surveiller les inondations dans une rivière désertique et un écosystème de zone humide désertique.

Des mesures spécifiques ont été prises pour traiter les données des images radar (fig. 30). La première étape est liée au prétraitement des données (mosaïquage, étalonnage, co-enregistrement, regroupement de bandes). Un sous-ensemble d'images a été créé pour réduire la taille des données et faciliter la gestion. Enfin, un filtre de nettoyage du speckle (filtre Lee avec une taille de fenêtre de 7×7) a été appliqué. Le Speckle ou chatoiement apparaît dans une image comme une texture granuleuse «sel et poivre». Cela est dû à la nature cohérente de l'onde radar qui donne des interférences constructives et destructives aléatoires dues aux multiples retours de diffusion se produisant dans chaque cellule de résolution. La deuxième étape concerne le traitement principal des données. En ce qui concerne la première méthode, pour la séparation des zones inondées et le suivi des zones humides, une approche de classification supervisée a été retenue. Tout d'abord, l'histogramme du coefficient de rétrodiffusion filtré de chaque bande dans l'image multibandes a été analysé. L'histogramme montre un pic d'une autre ampleur. Les valeurs faibles de la rétrodiffusion correspondent à l'eau et les valeurs élevées correspondent à la classe hors eau. Pour l'extraction de l'eau et des zones humides, nous avons appliqué une classification supervisée avec une approche combinée de classification de la texture et de l'intensité (Emran et al., 1996a ; Emran et al., 1996b).

Pour évaluer la précision de la classification, il a été suggéré qu'au moins 216 pixels sélectionnés au hasard environ de chaque classe d'occupation du sol devraient être vérifiés par rapport aux données de vérification de la vérité du terrain pour évaluer la précision des images classifiées (Pontius et Millones, 2011 ; Ayala-Izurieta et al., 2017). La précision globale, la

précision de l'utilisateur, le désaccord global, le désaccord sur la quantité et le désaccord sur la répartition ont été utilisés comme mesures de l'exactitude (Ayala-Izurieta et al., 2017).

La paire d'images SAR obtenues à partir de la bande Sentinel-1C comprend une image trois jours après l'évènement de crue, qui est appelée «image de crue», et une autre avant l'évènement de crue, qui est appelée «image de référence». Pour distinguer la zone inondée, un traitement de co-registration (Youssef et al., 2016 ; Chen et al., 2016a; Bayarjargal et al., 2006; Clement et al., 2017 ; Matgen et al., 2011; Ayala-Izurieta et al., 2017) a été appliqué.




Figure 30. La méthodologie appliquée aux données du radar à synthèse d'ouverture (SAR) représentée sous forme de diagramme de flux.

3.3 Résultats et discussion

Dans la première partie de cette section, nous présentons les informations issues de la surveillance de l'humidité / sécheresse du sol pour détecter les zones modifiées par les crues éclair en fonction des données optiques. Ensuite, nous présentons les informations obtenues à partir des données SAR. Ensuite, nous rapportons les résultats de la surveillance de l'étendue de l'eau après cette crue éclair. Enfin, nous présentons une discussion sur ces résultats.

3.3.1 Cartographie des changements obtenu à partir des données optiques

3.3.1.1 Caractérisation des zones modifiées causées par des crues soudaines à l'aide d'indices de changement Δ (albédo) et Δ (NDMI)

Les indices de changement Δ (Albédo) et Δ (NDMI) créent une sortie de changement détecté, où les valeurs varient en $[-1; 1]$ et sont caractérisées par les histogrammes à trois modes de la figure 31. Le mode principal correspond à l'état de non-changement dans l'image (valeur d'environ 0), et les zones jaune et cyan dans l'image de changement et les deux modes secondaires se réfèrent aux changements. Le premier mode secondaire en rouge (Δ (Albédo) ≈ -1 et Δ (NDMI) ≈ -1) correspond aux changements négatifs (remplissage ou submersion), tandis que le mode secondaire suivant en bleu (Δ (Albédo) ≈ 1 et Δ (NDMI) ≈ 1) correspond à des changements positifs (soutirage ou émergence). La submersion dans l'eau (changements négatifs) apparaît en rouge sur l'indice de changement affiché dans la couleur indexée, tandis que les zones émergentes (changements positifs) apparaissent en bleu sur la figure 32.




Figure 31. Histogramme des images de changement.




Figure 32. Δ (Albedo) Variation de l'indice de l'OLI deux semaines après l'évènement.

3.3.1.2 Analyse qualitative des changements par le composite couleur de l'espace caractéristique (Δ (albédo), Δ (NDMI))

La figure 33 a – c montre le RVB composite couleur à différents moments après l'évènement d'inondation, le rouge indiquant Δ (Albédo) et le vert et le bleu indiquant Δ (NDMI). Dans ces images, les zones en rouge représentent les zones dans lesquelles l'albédo a subi le changement maximum entre les deux dates - avant et plusieurs points temporels après l'inondation - et les zones en cyan clair représentent les zones où le NDMI a subi le changement maximum entre les deux dates. Ce sont le lit de la rivière et les zones de Sebkha dont les surfaces ont changé avec le temps après les inondations (fig. 33).




Figure 33. RVB composite couleur (rouge = $\Delta(\text{albedo})$, vert et bleu = $\Delta(\text{NDMI})$) pendant (a) un jour après, (b) deux semaines après et (c) deux mois après l'inondation.

3.3.1.3 Cartographie des changements catégoriques avec SVM

Les zones de l'image peuvent être classées en six catégories : eau, terre, Sebka, bâtiment, zone agricole et tempête de sable. La figure 34a – c montre trois périodes dans le temps : avant l'évènement de crue, un jour après l'évènement et deux semaines après l'évènement. Visuellement, les performances globales du SVM dans la classification de l'occupation du sol sont bonnes, car il peut classer tous les pixels efficacement. Une analyse de précision a été réalisée en comparant les pixels classés avec des pixels réels au sol à l'aide d'une matrice de confusion (Pontius et Millones, 2011 ; Ayala-Izurieta et al., 2017). À des fins d'évaluation de la précision, la sélection des pixels de vérité au sol a été effectuée par échantillonnage aléatoire avec une répartition d'échantillons égale dans chaque strate (216 pixels sélectionnés au hasard

approximativement pour chaque classe de couverture terrestre). La précision globale des catégorisations utilisant ce sous-ensemble de données est de 86,45% (voir tableau. 9). Cette valeur est faiblement acceptable si l'on considère les difficultés de la région étudiée et que nous n'avons utilisé que 221 pixels pour entraîner l'algorithme. Les pourcentages des classifications correctes des pixels comme bâtiment, Sebkhha, tempête de sable, sable, agriculture et eau sont respectivement de 87,3%, 84,7%, 77,8%, 88%, 88% et 82,5%. Pour ces trois classifications, la valeur du coefficient d'accord se situe entre 88,8 et 92,5%, le désaccord sur la quantité se situe entre 2,66 et 3,78, le désaccord sur l'allocation se situe entre 3,27 et 4,5 et enfin, le désaccord global se situe entre 5,93 et 8,28. Toutes ces valeurs montrent que la classification SVM et les données réelles des pixels de vérité au sol sont relativement bien d'accord (Ayala-Izurieta et al., 2017).




Figure 34. Résultat de la classification des machines à vecteurs supports (SVM) pour (a) avant l'inondation, (b) un jour après l'inondation et (c) deux semaines après l'inondation.

Tableau 9. La matrice d'erreur montrant les performances de précision globale (OA) exprimées en nombre de pixels.

Référence (Ground Truth)	Classe						Évaluation de la précision%				
	Bâtiment	Sabkha	Tempête de sable	Le sable	Agriculture	Eau	n_{j+}	O_{Er}	U_{je}	P_{je}	OA
Bâtiment	191	3	5	3	2	dix	211	10,9	89,1	87,3	86,45
Sabkha	2	186	5	2	dix	6	209	12	88	84,7	
Tempête de sable	sept	13	180	4	4	sept	211	16,6	83,4	77,8	
Le sable	6	3	12	188	2	8	219	12,3	87,7	88	
Agriculture	3	sept	sept	6	192	dix	219	15	85	88	
Eau	9	sept	19	13	8	180	223	25,1	74,9	81,5	
n_{+j}	212	216	216	216	216	221	1292				
C_{Er}	12,7	15,3	22,2	12	12	18,5					

Les étiquettes du résultat de la classification (pixel classé par classe) sont les colonnes, tandis que les étiquettes de la carte de référence (pixel de référence par classe) sont les lignes; $n_i +$ et n_{+j} sont le total des lignes et colonnes précédentes, respectivement. Abréviations: erreur d'omission (O_{Er}), erreur de commission (C_{Er}), précision de l'utilisateur (U_i), précision du producteur (P_i) et précision globale (OA).

3.3.1.4 Surveillance des informations sur les zones humides d'humidité / de sécheresse par fusion du traitement spectral et du traitement catégorique

Les résultats de la classification du modèle SVM avant l'évènement de crue éclair et chaque intervalle de temps qui a suivi ont été utilisés pour extraire la limite de la zone de changement. Ensuite, nous avons utilisé la segmentation de la direction (à l'aide de l'équation (10)) et de la magnitude (à l'aide de l'équation (9)) des changements qui se sont produits dans ces zones d'inondation, donnée par les différences de classification SVM entre pré-inondation et post-inondation (à différents moments). Les zones sans changement dans la classification SVM n'ont pas été utilisées dans la segmentation des résultats du processus CVA. Figure 35a, b et c montrent la segmentation de la direction (à l'aide de l'équation (10)) et de l'amplitude (à l'aide

de l'équation (9)) des changements qui se sont produits dans la zone d'étude avant l'évènement aux différentes périodes utilisées après l'évènement. Il n'y a eu aucun changement dans 93% de la superficie; 3,5% de la zone présente un certain degré d'humidité, et un changement de 3,2% s'est produit dans la zone de sécheresse, correspondant à la rivière et au Sebkhah un jour, deux semaines et deux mois après l'évènement. L'amplitude de la variation de la sécheresse du sol dans la zone d'étude a été classée en trois catégories: sol à faible sécheresse, sol à sécheresse moyenne et sol à sécheresse élevée. L'ampleur de la variation de l'humidité du sol a été classée selon trois catégories: sol très humide, sol moyennement humide et eau libre.




Figure 35. Carte des changements (a) un jour après l'inondation, (b) deux semaines après l'inondation et (c) deux mois après l'inondation.

On peut le voir sur la figure 35 que les principaux sujets d'intérêt, à savoir la rivière et la Sebkhah, présentent tous deux une variation de l'échelle d'humidification de leurs surfaces un

jour seulement après les inondations. Deux semaines après l'évènement, seule une partie de la rivière reste humide. L'observation démontre que la Sebkha sud présente une surface plus sèche qu'avant les inondations, sauf aux limites de la zone entre la dune de sable et les bords de cette Sebkha. De plus, la Sebkha située au nord reste humide dans la majorité de sa zone. Deux mois après les inondations, nous constatons que le fleuve revient à son état normal, et que la Sebkha sud est nettement plus sec, sauf dans la partie nord, humide sur la moitié de sa surface. En résumé, l'approche collaborative combine les avantages des deux processus: le traitement catégoriel définit les bords précis des principales classes de changements et ne peut pas faire la distinction entre les types de changements; dans le traitement spectral, les valeurs de pixels dans les bandes originales sont traitées comme des vecteurs de données de différence transformées en plus d'un vecteur de changement (CV) calculé en soustrayant les vecteurs pour tous les pixels à des dates différentes. La direction du CV représente le type de changement, tandis que l'amplitude du vecteur de changement correspond à la longueur du CV (Chen et al., 2016b).

3.3.2 Cartographie des changements obtenue à partir des données SAR

La carte de l'étendue des crues obtenue à partir de cette méthode (coregistration, classification) a été comparée et évaluée. La carte des changements résultant de la classification supervisée, qui est basée sur une combinaison des approches de texture et d'intensité, est illustrée à la figure 36b. Sur la figure 36, la zone inondée composée de sols très humides apparaît en rouge, ce qui représente des zones avec une rétrodiffusion accrue en raison du niveau considérable d'humidité du sol. Les zones en bleu sont les zones inondées qui restent couvertes d'eau trois jours après les inondations; ce sont des zones agricoles inondables avec une rétrodiffusion réduite. L'étendue totale de l'eau a été estimée à 36,2 km² (3620 hectares). Le plan d'eau régulier dans le barrage (fig. 36 a) avant la crue est de 12 km² (1200 hectares). Par conséquent, la zone inondée pour cette période est de 24,2 km² (2420 hectares). Cette classification des images Sentinel-1 co-registrée donne une précision globale de 0,90 et la valeur du coefficient d'accord est de 89,9%.




Figure 36. (a) Composition colorée des canaux co-registrés des bandes de polarisation VV. Rouge: après inondation; bleu et vert: avant inondation. (b) Carte des changements. Rouge: augmentation de la rétrodiffusion; bleu: diminution de la rétrodiffusion.

3.3.3 Suivi de l'étendue d'eau de la rivière après une crue éclair

Pour pouvoir extraire l'étendue de l'eau, toutes les zones avec un sol humide ont été fusionnées et regroupées en une seule classe d'eau. L'étendue pré-inondation d'un plan d'eau régulier dans le barrage (fig. 37 a) est de 12 km². Pendant le pic d'inondation, un jour après l'évènement, la zone inondée est de 29,44 km² (fig. 37 b). Deux semaines après l'évènement, la zone inondée est de 8,48 km² (fig. 37 c). Enfin, deux mois après l'évènement, la zone inondée est proche de zéro: 0,35 km² indiquant un retour à un plan d'eau régulier dans le barrage (fig. 37 d). La figure représente la variation de l'étendue des crues obtenue par la moyenne de MSI et OLI avant l'évènement de crue comme référence, MSI un jour après l'évènement, OLI deux semaines après l'évènement et MSI deux mois après l'évènement. Dans l'image radar de la région trois jours après l'inondation, les zones en bleu, qui correspondent à une diminution de la rétrodiffusion, peuvent être désignées avec certitude comme des surfaces d'eau. Cependant, les zones rouges qui correspondent à une augmentation de la rétrodiffusion ne peuvent pas être désignées avec certitude comme des surfaces d'eau, car il pourrait s'agir d'une augmentation de la rugosité de surface. Enfin, nous remarquons que les résultats obtenus à partir des images

optiques sont en accord avec ceux obtenus avec le capteur radar. Cependant, nous ne pouvons affirmer avec certitude la présence d'eau dans les zones à rétrodiffusion croissante.




Figure 37. (a) Étendue de l'eau du barrage avant l'évènement de crue éclair, (b) un jour après l'évènement, (c) deux semaines après l'évènement, et (d) deux mois après l'évènement.

3.3.4 Suivi de l'étendue de l'eau de Sebkha et de l'humidité du sol après une crue éclair

L'étendue d'un plan d'eau régulier dans la Sebkha (fig. 38a) avant l'évènement d'inondation est de 0,05 km², ce qui représente la cavité d'eau permanente dans la Sebkha sud. Pendant le pic d'inondation un jour après l'évènement (fig. 38b), l'étendue est de 8,35 km² pour la Sebkha sud et de 9,64 km² pour le Sebkha nord. Trois jours après l'évènement (fig. 38c), selon les données SAR, l'étendue est de 6,2 km² pour la Sebkha sud et de 5,50 km² pour celui du nord. Deux

semaines après l'évènement (fig. 38d), l'étendue de la zone humide était de 1,48 km² pour la Sebkhia sud et de 5,75 km² pour celui du nord. Enfin, deux mois après l'évènement (fig. 38e), l'étendue de la zone humide est de 6,8 km² ; il est proche de l'étendue avant l'évènement pour la Sebkhia sud, indiquant un retour à la masse d'eau régulière dans la cavité d'eau permanente de la Sebkhia. Cependant, celle du nord reste humide avec une superficie de 2,75 km². Ainsi, nous pouvons conclure que les réponses des deux sabkhas à cette tempête ne sont pas les mêmes. La Sebkhia sud a des pertes de transmission plus importantes que le nord.




Figure 38. (a) Étendue d'eau de Sebkhia avant la tempête et (b) un jour après, (c) trois jours après, (d) deux semaines après, et (e) deux mois après l'évènement.

3.3.5 Discussion et proposition d'un flux de travail pour le développement d'un JN pour la résilience aux inondations

La méthode proposée pour les données radar SAR améliore fortement la fiabilité des classifications des crues dans les régions arides, où les surfaces sableuses entraînent généralement une forte surestimation de l'étendue de l'eau avec les données SAR (Martinis et al., 2018). Dans l'image co-registrée, les zones qui correspondent à une diminution de la rétrodiffusion peuvent être désignées avec certitude comme des surfaces d'eau. Cependant, les zones qui correspondent à une augmentation de la rétrodiffusion ne peuvent pas être désignées avec certitude comme des surfaces d'eau, car elles pourraient être causées par une augmentation

de la rugosité de surface due au transport de matériaux par les eaux de crue. De plus, cette étude montre que l'étendue de l'inondation estimée à partir d'images radar est en continuité spatio-temporelle avec l'étendue de l'inondation estimée à partir d'images optiques si l'on considère que les zones d'augmentation de la rétrodiffusion correspondent à des zones inondées.

Le Sebkha sud a des pertes de transmission plus importantes que le nord en raison de sa profondeur relativement faible, comme le montre la figure 39, dans laquelle la Sebkha nord a une plus grande profondeur que le sud, et a donc une plus grande capacité à retenir l'eau de pluie que le Sebkha sud. Il y a une évaporation importante, car la Sebkha qui se trouve au nord est directement exposée au courant de vent froid venant du nord, comme observé sur les images satellites optiques. Tous ces effets font que l'eau résiduelle restante après cet événement diminue rapidement, donc cette Sebkha sèche plus rapidement.




Figure 39. Profil topographique du nord au sud illustrant la morphologie du Sebkha, ce qui conduit à une plus grande rétention d'eau dans la Sebkha nord par rapport au sud.

Proposition du flux de travail pour le développement d'un JN de résilience aux inondations.

La création d'un JN pour permettre la résilience aux inondations implique l'intégration de la modélisation de la réalité à l'échelle de la ville, de la cartographie 3D et de la modélisation des inondations. Le modèle de résilience aux inondations résultant peut être utilisé pour l'analyse, la simulation, la visualisation et la communication. Pour commencer dans ce flux de travail, un logiciel de modélisation de la réalité et de cartographie 3D doit être utilisé pour générer un maillage de réalité 3D haute résolution à l'échelle de la ville en utilisant des photos superposées

de drones et des images au sol, complétées par des scans laser au sol et mobile en utilisant par exemple Leica Pegasus Backpack Solution mobile pour capturer la réalité qui est une solution 3D mobile portable. Le modèle / maillage de capture de la réalité est classifié spatialement, ce qui signifie que les bâtiments, parcelles et autres éléments du paysage urbain maillé sont liés à des données SIG sous-jacentes et applicables. Le modèle de réalité est également nativement prêt pour l'ingénierie, avec une résolution et une évolutivité suffisante pour zoomer sur une zone et effectuer des travaux d'ingénierie directement hors du maillage. Et surtout, le modèle de réalité comprend des données numériques de terrain, ce qui est fondamental pour toute simulation hydrologique. Ensuite, un modèle de résilience aux inondations est créé en mettant en place un maillage de calcul pour la zone d'intérêt, que ce soit la ville entière ou seulement une fraction de celle-ci. Ce maillage de calcul est ensuite rempli de données utilisées pour les simulations d'inondation. Les données numériques du terrain peuvent être extraites directement du modèle de capture de la réalité pour fournir des données de surface précises pour le logiciel de modélisation des crues ainsi qu'un contexte visuellement réaliste pour visualiser les simulations de crue. Le modèle issu de la capture de réalité peut également être utilisé pour identifier les rues, les trottoirs, les espaces verts, les arbres et d'autres informations requises par le modèle de résilience aux inondations. Le logiciel d'inondation utilise des modèles numériques pour simuler une gamme de processus hydrauliques et hydrologiques, y compris les précipitations, l'infiltration, le ruissellement de surface, l'écoulement des canaux et l'écoulement des eaux souterraines. Il peut également intégrer des flux en temps réel concernant les nouvelles données météorologiques, les conditions hydrologiques actuelles et les états opérationnels des actifs d'infrastructure existants, par exemple. Il serait possible d'inclure les quantités de précipitations récentes, les débits actuels du fleuve, l'état de fonctionnement des pompes, etc. Et, étant donné la nature omniprésente des téléphones mobiles et des médias sociaux, il pourrait même y avoir des flux en direct documentant les inondations localisées des rues et des marées pour soutenir la gestion des crises liées aux inondations. Le modèle est actualisé en continu à partir de plusieurs sources - telles que des capteurs IoT, des levés continus ou des mises à jour SIG - pour représenter les conditions actuelles.

3.4 Conclusion

Cette recherche s'est concentrée sur la surveillance de l'étendue de l'eau dans une zone humide après des crues éclair dans la région saharienne du Maroc. À l'aide de données spatiales multicapteurs, nous avons montré les changements de l'étendu de l'eau spatialement dans cette zone après un évènement de crue éclair à l'échelle locale. Cette étude a utilisé des données optiques, des données SAR radar et des approches collaboratives en combinant un traitement spectral et catégorique. Les indices spectraux dérivés de l'imagerie optique de télédétection multi-temporelle ont été utilisés pour montrer les changements radiométriques, tandis que le traitement catégorique a été utilisé pour montrer les changements thématiques. Enfin, la fusion des deux processus a abouti à la carte des changements présentée ci-dessus. Le traitement spectral comprend des indices spectraux tels que l'albédo, le NDWI, le NDMI et le NMDI, décrivant la courbe de réflectance du sol.

Cependant, dans l'environnement désertique, les données optiques deviennent aussi importantes que les données radar et donnent de meilleurs résultats. Ce travail montre que le retour à la situation normale de l'eau dans le barrage après une inondation dans un environnement aride a pris environ deux mois, et le niveau d'eau normal de la Sebkha a été brièvement réduit, ce qui a fait que la Sebkha devenait plus sec au fil du temps. De plus, notre méthodologie a déterminé la taille de la zone directement touchée par les crues. Il a en outre démontré que l'évolution de l'étendue des inondations extraites de l'image radar présente une similitude avec l'étendue des inondations extraites des images optiques. De plus, cette étude a suivi l'état d'humidité de la surface suite à une crue éclair dans une région aride, dans le but de présenter les causes sous-jacentes et permettre une bonne gestion des risques.

En effet, les résultats peuvent aider à améliorer la gestion des ouvrages de régulation de l'eau en développant une méthodologie pour maximiser la capacité de stockage de l'eau et réduire les risques d'inondations éclair à Laayoune et ses régions. Enfin, les résultats obtenus montrent que la contribution des images SAR à la cartographie des crues est complémentaire aux images

optiques, et que la fusion des résultats spectraux et catégoriques des multi-capteurs augmente la précision et la continuité, contribuant ainsi à une meilleure surveillance des zones humides désertiques.

Enfin, dans les perspectives de ce travail, nous présentons une approche à la concrétisation et le développement d'un JN pour la modélisation de la vulnérabilité, de la résilience dynamique et la simulation en temps réel des inondations.

Chapitre 4 : Évaluation des changements dans l'état humide / sec de surface des cavités d'eau de la Sebkha d'Imlili dans le sud-ouest du Maroc en utilisant la classification d'apprentissage automatique dans Google Earth Engine.

4.1 Introduction

Les Sebkhas sont des dépressions humides dans des environnements désertiques qui sont généralement considérées comme des plaines inondables présentant un intérêt environnemental important et ont été étroitement liées à de nombreux problèmes environnementaux, tels que le changement climatique, la qualité de l'eau, l'habitat faunique et la biodiversité. Des études récentes menées par l'Institut scientifique de Rabat et l'Association Nature Initiative de Dakhla se sont concentrées sur la Sebkha d'Imlili dans le sud du Maroc, dont les structures géomorphologiques ont conservé les impacts des conditions climatiques antérieures au Sahara (Qninba et al., 2009; Lévêque, 1990; Trape, 2009; Trape, 2016; Qninba et al., 2012; Bennas et al. 2016). Les Sebkhas sont des plateaux de sable supratidaux qui se forment le long des côtes arides. Ces reliefs ont des dépôts de carbonate évaporé avec des siliciclastiques et forment des

séquences subaériennes, de progradation et de haut-fond avec une épaisseur moyenne de 1 m ou moins (Gorelick et al., 2017). Des études antérieures ont montré que les régimes paléoclimatiques au Maroc saharien alternaient entre périodes sèches et humides tout au long du Pléistocène et que les réserves des aquifères fossiles sahariens sont remplies pendant les périodes humides (Foucault, 1994; Abotalib et al., 2016). L'approvisionnement en eau de ces poches n'est pas aléatoire et est garanti par les petites résurgences qui apparaissent à la partie inférieure de la zone, préservant ainsi l'humidité sur la surface des eaux souterraines du sol de la Sebkha, en particulier aux bords ouest et nord de la zone (Yan et Petit-Maire, 1994). Alors que la partie médiane de cette Sebkha contient plusieurs dizaines de poches d'eau permanente (161 poches) avec des diamètres allant de 1 m à 10 m, ces poches ont une profondeur d'environ 4,6 décimètres et une salinité de l'eau de 24 g/l à 350 g/l (fig. 40 a). Cependant, ces poches d'eau abritent de nombreux animaux et poissons (fig. 40 b) comme indiqué lors d'une excursion scientifique en avril 2017. En fait, ni le paysage général ni les données climatiques de la région ne suggèrent l'existence de cavités permanentes d'eau salée qui sont capable d'abriter des poissons. Bien que sa salinité élevée ait provoqué la fuite des oiseaux, la Sebkha d'Imlili a créé un habitat favorable pour une espèce de poisson cichlidé associée à *Tilapia guineensis*, une espèce auparavant inconnue au Maroc et dont la limite nord était auparavant limitée au fleuve Sénégal.



Figure 40. Une cavité d'eau permanente dans la Sebkha d'Imlili (a) abritant une faune de l'espèce *Tilapia* (b).

L'eau de pluie est une autre source d'eau pour ces fouilles. Bien que rare sous ces latitudes, l'eau de pluie est transportée vers la Sebkha via des cours d'eau temporaires, dont le plus

important est situé dans la zone humide. La Sebkha d'Imlili est également classée comme écosystème Ramsar, vestige d'un ancien réseau aquatique au Sahara. Toutes ces raisons font de la Sebkha l'Imlili un domaine d'étude intéressant pour les scientifiques. Le tableau 10 montre l'aire et la profondeur de ces cavités.

Tableau 10 Superficie (m2) et profondeur (cm) des cavités d'eau permanentes de la Sebkha d'Imlili.

Surface minimale	0,015	Profondeur minimale	20.115
Surface maximale	472.617	Profondeur maximale	460
Surface moyenne	18,769	Profondeur moyenne	80
Écart-type	43,477	Écart-type	73,57

Google Earth Engine (GEE) (<https://earthengine.google.com/>) est une puissante plate-forme Web pour le traitement et l'analyse à grande échelle, dans le cloud, des données géospatiales Big Data. Ce moteur contient des images satellites archivées prises dans le monde entier et des milliards de mesures scientifiques qui remontent à près de 40 ans. Cette plateforme propose également un service d'interface de programmation d'applications (API) et d'autres outils que les scientifiques et les chercheurs peuvent utiliser pour analyser les Big Data géospatiales en détectant et en surveillant les changements de l'occupation du sol et en cartographiant les tendances et en quantifiant les différences à la surface de la Terre (Bleeker, 1865). GEE est une archive de pétaoctets de données d'observations de la Terre (OT) qui fournit et relie des données à l'aide d'un logiciel de traitement efficace codé en JavaScript ou en Python et décrit ces données au format API. Dernièrement, il est aussi disponible comme extension sous le logiciel libre QGIS. Grâce à ses outils de cloud computing hautes performances, les utilisateurs peuvent effectuer des analyses et des visualisations géospatiales complexes sur GEE. La GEE et ses outils API permettent aux utilisateurs d'obtenir, d'analyser, de visualiser et de traiter les informations d'OT pour n'importe quelle zone spécifiée sans avoir besoin d'importer des données spatiales et d'exporter les résultats de l'analyse vers l'environnement de bureau de l'utilisateur. L'utilisation de plateformes cloud permet aux utilisateurs de traiter efficacement

de gros volumes de données. Ces données incluent des images satellites, qui sont largement consommées dans des tâches de calcul intensif, telles que la classification, l'analyse spectrale, l'analyse des séries temporelles et l'extraction des caractéristiques, surtout lors de l'utilisation d'algorithmes avancés, comme les machines d'apprentissage automatique. GEE est un outil d'analyse géospatiale basé sur le cloud gratuit et en accès libre qui peut être utilisé à des fins éducatives et à but non lucratif (Google Earth Engine, 2012) et peut fournir une interface accessible en ligne à tout utilisateur disposant d'un compte Google. En plus de son API JavaScript, la GEE dispose de jeux de données et d'algorithmes pertinents pour la cartographie régionale et mondiale et d'une vaste collection de données d'images (y compris presque toutes les archives Landsat et Copernicus) auxquelles les développeurs peuvent accéder directement pour vérifier et créer des algorithmes et afficher leurs résultats presque instantanément. Les données archivées dans la GEE comprennent des données de signaux (par exemple, des données topographiques, climatiques, optiques et radar) et des données thématiques (par exemple, des données sur l'occupation du sol). Pour les données optiques, Landsat offre la plus grande archive en libre accès de données d'OT. Cette étude a utilisé des données archivées Landsat-5 Thematic Mapper TM de 1984 à 2012, des données Landsat-8 Operational Land Imager (OLI) de 2013, des données synthétiques d'ouverture radar (SAR) Sentinel-1 de 2014, et données multispectrales optiques (MSI) Sentinel-2 de 2015. La surveillance de l'emplacement des cavités d'eau à partir de données spatiales multisources dans la Sebkh d'Imlili a posé trois défis. Le premier défi concernait la méthode de collecte d'images, qui devait garantir une couverture d'image maximale avec une couverture nuageuse limitée. Le deuxième défi consistait à mettre en place une plateforme cloud pour le prétraitement des données d'images et le stockage des images. Le troisième défi consistait à concevoir des méthodes pour cartographier les changements dans les données de l'état d'humidité / sécheresse de surface de la Sebkh d'Imlili tout en garantissant la cohérence des résultats. Nous avons profité de la puissance de calcul de GEE et soutenu le processus de collecte d'images pour surmonter les deux premiers défis mentionnés ci-dessus. Quant au troisième défi, nous avons adopté une méthode basée sur l'indice pour collecter des données optiques et radar. Étant donné que nous avons exploité deux propriétés des cavités aquatiques dans notre travail, à savoir la

présence d'eau dans les cavités et la présence de sels, nous avons calculé deux indices spectraux à partir des images optiques, à savoir l'indice d'eau toutes bandes (ABWI) et la salinité indice (SI). À partir des données Sentinel-1 SAR Ground Range Detected (GRD), nous avons déterminé un indice de polarisation différentielle normalisé aux micro-ondes (MNDPI) à partir de toutes les images de polarisation verticale – horizontale (VH) et verticale – verticale (VV) capturées par ce capteur à partir de 2014. Des études antérieures ont montré que les méthodes basées sur l'indice sont efficaces pour les applications qui utilisent GEE avec différentes sources d'images, comme Landsat l'indice d'eau toutes bandes (ABWI) et l'indice de salinité (SI). À partir des données Sentinel-1 SAR Ground Range Detected (GRD), nous avons déterminé un indice de polarisation différentielle normalisé aux micro-ondes (MNDPI) à partir de toutes les images de polarisation verticale – horizontale (VH) et verticale – verticale (VV) capturées par ce capteur à partir de 2014. Des études antérieures ont montré que les méthodes basées sur les calculs d'indices sont efficaces pour les applications qui utilisent GEE avec différentes sources d'images, comme Landsat (Patel et al., 2015; Margono et al., 2014; Pradhan et al., 2018; Teluguntla et al., 2018; Johansen et al., 2015; Liu et al., 2018), the Advanced Land Observing Satellite and the Phased Array type L-band Synthetic Aperture Radar ALOS / Palsar (Patel et al., 2015), et Sentinel-1,2 (Mahdianpari et al. 2019).

Le SAR est une technique de télédétection active qui peut pénétrer la couverture nuageuse, fonctionner de jour comme de nuit et permettre une classification efficace des eaux de surface (Mahdianpari et al. 2019). Les images radar sont bien adaptées pour étudier et surveiller les zones désertiques (Lee et Pottier, 2009). La sensibilité de ces images aux variations de pente de la surface topographique peut faciliter les analyses géologiques et géomorphologiques (Dobson et al., 1997). Des études antérieures ont utilisé des satellites SAR à polarisation unique et classé les propriétés de surface des Sebkhass en fonction de leur distribution granulométrique et de la composition de leur roche prédominante (Touzi et al., 2004a). Cependant, les objets Sebkhass n'ont été classés qu'en fonction de l'intensité de l'énergie rétrodiffusée, connue sous le nom de section radar (σ°) des données SAR à double polarisation calibrées, ce qui conduit à des estimations inexactes de la rugosité et de la taille des grains (Baghdadi et al., 2002; Gaber

et al., 2010; Saraf, 2010). La quantité d'ondes SAR rétrodiffusées est affectée par deux paramètres, à savoir la rugosité de la surface (hauteur quadratique moyenne) et la constante diélectrique de la surface (ϵ_0), qui montrent une relation linéaire (Koch et El-Baz, 2000). Le degré de rugosité de la surface est contrôlé par la topographie générale, la pente et la taille des particules de l'objet de surface, tandis que la valeur de la constante diélectrique est basée sur la teneur en humidité volumétrique (θ_v) et la conductivité (homogénéité) de l'objet de surface (Touzi et al., 2004a; Melsheimer et al., 1999; Baghdadi et al., 2006). En conséquence, les données SAR à double polarisation ont fourni une valeur de rétrodiffusion double pour chaque pixel d'une scène (VV et VH). En utilisant ces données SAR polarimétriques doubles, des informations supplémentaires, telles que l'indice de polarisation ou la dépendance à la réflectivité de la polarisation, peuvent être déterminées pour chaque pixel de la scène en calculant à la fois l'intensité des ondes rétrodiffusées et le changement de leur phase (ϕ) et intensité (Moran et al., 2004). La signature de polarisation radar d'une cible a permis des déductions plus fortes du mécanisme de rétrodiffusion physique que des mesures de polarisation unique en identifiant et en caractérisant le mécanisme de rétrodiffusion dominant (Touzi et al., 2005; Touzi et al., 2002; Touzi et al., 2004b). Par conséquent, la solution pour la forme géométrique et la constante diélectrique d'un objet est devenue moins ambiguë (Touzi et al., 2004a). Une telle polarimétrie radar peut être utilisée pour la discrimination et la caractérisation d'objets dans Sebkhas (Dobson et al., 1997).

Dans ce travail, la plateforme GEE a été utilisée pour (1) surveiller les états salinité des cavités d'eau permanentes dans la Sebkha d'Imlili, (2) surveiller les conditions de d'humidité de surface / de sécheresse de surface de ces cavités, (3) évaluer la capacité du cloud computing à traiter plusieurs types de données, y compris les indices spectraux ou polarimétriques sur les multiscapteurs et l'imagerie multitemporelle, et (4) analyser la fonction du système aquifère de la Sebkha en examinant un réseau souterrain enterré et cartographier l'emplacement des cavités d'eau salée avec une précision nettement supérieure par rapport à ce qui peut être atteint en utilisant les données gratuites disponibles sur la plate-forme GEE. L'objectif principal de cet article était de surveiller l'évolution des cavités d'eau dans la Sebkha d'Imlili sur une certaine période. Plus précisément, ce document a utilisé les fonctionnalités de GEE pour surveiller la

Sebkha d'Imlili en extrayant son humidité, son sel, et des indices de l'eau et contribuer au développement d'une méthodologie basée sur GEE. De plus, la combinaison radar / optique a été utilisée pour extraire des informations hydrogéologiques et géomorphologiques, et les possibilités de classification par approche Machine Learning en utilisant les forêts aléatoires (Random Forest) qui ont été utilisées pour améliorer la précision de la cartographie dans cette région désertique.

4.2 Matériels et méthodes

4.2.1 Zone d'étude et physiologie générale

Imlili Sebkha est situé dans le sud du Maroc (2381703000–2381104500 N, 1585604100–1585303700 O) à 40 km au sud d'El Argoub et à 15 km à l'est de l'océan Atlantique (fig. 41). La vaste zone est composée de plus d'une centaine de poches d'eau permanente et de sel. La forte salinité de cette zone a provoqué la fuite des oiseaux de la région tout en offrant un habitat favorable à une espèce de poisson cichlidé associée à *T. guineensis*, une espèce jusqu'alors inconnue au Maroc dont la limite nord était limitée au fleuve Sénégal (Afrique de l'Ouest) avant sa récente découverte sur un affluent de l'Oued Chebeika et du Banc d'Arguin en Mauritanie. La température dans la région varie de 5 ° en hiver à 48 ° en été avec des précipitations courtes et irrégulières. La Sebkha d'Imlili est également exposée aux vents et aux tempêtes de sable, a une pluviométrie annuelle allant de 50 mm à 60 mm, et dispose d'un approvisionnement suffisant en brouillard et en rosée pour maintenir un type de végétation semi-désertique dans les lits des petits oueds et Sebkhas (Rjimati et al., 2010 ; Saddiqi et al., 2011 ; Cloude et Papathanassiou, 1998).




Figure 41. Emplacement de la Sebkhia d'Imlili et de ses cavités d'eau salée. (A) Maroc, (B, C) localisation de la Sebkhia, (D) prospection d'une partie de la Sebkhia contenant plusieurs trous d'eau vue depuis Google Earth (16 janvier 2018).

4.2.2 Données d'observation de la Terre

Le tableau 11 présente les ensembles de données spatiales et de référence utilisées dans cette étude. Ces données comprennent plusieurs images multisources qui ont été utilisées pour dériver les indices spectraux et les propriétés physicochimiques des cavités aquatiques (par exemple, salinité, pH, profondeur de l'eau, résistivité et présence ou absence de poisson) qui ont été utilisées pour valider les résultats du projet méthode. Au total, 520 images satellites optiques et 211 images satellites radar ont été consultées et analysées au sein de GEE.

Tableau 11 Ensembles de données utilisés dans cette étude et les indices spectraux et polarimétriques extraits de ces données.

La source de données	Caractéristiques	Indices extraits
Imagerie optique	280 images individuelles de 30 m TM / Landsat-5 acquises dans la zone d'étude en 1984, 1994 et 2004	—Indice d'eau utilisé dans cette étude (ABWI) —Indice de salinité par différence normalisée (NDSI) —Indice de cavité d'eau salée (SWCI)
	83 images individuelles MSI / Sentinel-2A de 10 m acquises dans la zone d'étude en 2017	—Indice de cavité d'eau salée optique / sar (SOSWCI)
	50 images individuelles MSI / Sentinel-2A de 10 m acquises dans la zone d'étude en 2019	
Imagerie radar	211 images individuelles de détection de portée au sol Sentinel-1 SAR collectées à une résolution spatiale de 10 m de 2015 à aujourd'hui	—Indice de polarisation par différence normalisée aux micro-ondes (MNDPI) —SAR / Indice de cavité saline optique (SOSWCI)
Donnée de référence CHIRPS Precipitation Data	Données basées sur des points vectoriels qui représentent la position des cavités d'eau Spatial: 0,05 ° Plage de dates: 1985-2019	Caractéristiques des cavités d'eau dans le tableau d'attributs Graphique des précipitations généré par ClimateEngine.org

Un modèle numérique d'élévation (DEM) à résolution spatiale de 30 m a été obtenu à partir de la base de données Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) et préparé dans un logiciel SIG libre (QGIS). Ce modèle nécessite plusieurs mesures, telles que le remplissage des lacunes, le tri spatial et l'analyse des sous-ensembles de la région extraite (fig. 42 a). Les images radar Sentinel-1 en bande C de niveau 1 détectées par la portée au sol (GRD) ont été collectées à une résolution spatiale de 10 m (fig. 42b). Le Thematic Mapper (TM) / Landsat-5 (fig. 42c) et Sentinel-2 MSI sont illustrés à la figure 42 d. Les images Landsat-5 TM ont été acquises le 2 juin 1984, le 6 août 1994 et le 21 avril 2004, tandis que les images Sentinel-2 MSI ont été acquises le 16 avril 2017 et le 10 avril 2019. La résolution spatiale des images Landsat était de 30 m, alors que celle des images Sentinel-2 était de 10 m. Les matériaux ont été fournis au sol et géoréférencés dans le système de coordonnées UTM, Universal Transverse Mercator (projection WGS84 zone 28N), qui était la même projection du DEM Aster, TM Landsat-5, MSI Sentinel-2 et SAR (GRD) Images Sentinel-1.




Figure 42. (a) Modèle numérique de terrain (DEM) avec un réseau hydrologique et des cavités aquatiques, (b) Bande C Sentinel-1 (fréquence centrale de 5,404 GHz) GRD de niveau 1, (c) image Landsat thématique mapper TM-2004, et (d) Sentinel-2 MultiSpectral Instrument

4.2.3 Données sur l'état du sol mesurées sur le terrain

Les données ont été collectées du 14 avril 2017 au 16 avril 2017 lors d'une expédition sur site où une étude de terrain complète des sites ci-dessus a été réalisée. Au cours de cette expédition, les données ont été collectées in situ pour couvrir un large éventail de populations Sebkha potentielles. Les scientifiques ont effectué une mission hydrobiologique et ornithologique dans la zone couverte par la Sebkha d'Imlili, et leurs observations ont mis en évidence l'importance de ce site comme escale pour des dizaines de milliers d'oiseaux attirés par la concentration de

plantes et les poches d'eau permanentes développées dans un environnement désertique. Certains migrants sont la proie du tilapia de Guinée et d'autres espèces marines vivant dans les poches de sel de cette zone.

L'équipe scientifique a utilisé le système de positionnement mondial (GPS) pour géolocaliser les cavités aquatiques en tant que points et pour déterminer leurs propriétés (par exemple, salinité, pH, surface, profondeur de l'eau et résistivité). Plusieurs photographies numériques et observations auxiliaires (p. Ex. Présence ou absence de poisson) ont également été recueillies pour préparer les échantillons d'apprentissage lors du processus de classification par approche Machine Learning. Les points GPS enregistrés ont ensuite été importés dans Quantum GIS (QGIS), un logiciel gratuit, où des polygones indiquant les cavités d'eau délimitées classées ont été générés.

4.2.4 DEM, géomorphologie, hydrologie et géologie d'Imlili Sebkha

Comme toutes les sebkhas, la Sebkha d'Imlili représente une dépression sèche dans le désert. Compte tenu de la composition de la nappe phréatique en eau salée, les Sebkhas sont inondés de manière irrégulière par des événements de précipitations au cours desquels ils deviennent des lacs salés endoréiques de courte durée. La Sebkha d'Imlili est une dépression peu profonde de moins de 10 m de profondeur, d'environ 12 km de long et de 2,5 km de large dans la direction générale Nord/Nord-Est — Sud/Sud-Ouest (NNE – SSW). Cette Sebkha est entourée de dunes de sable et les plantes forment une bande étroite (de 20 à 30 m de long) principalement sur ses limites ouest et nord. Les géomorphologues définissent généralement la zone sablonneuse dans la partie nord d'une Sebkha comme une dépression à fond plat où les sols salins limitent la croissance de la végétation. Les Sebkhas dans les pays désertiques ou les régions arides représentent une dépression temporairement occupée par un lac généralement salé qui contient des dépôts d'évaporite. Dans la Sebkha d'Imlili, l'eau provient non seulement du ruissellement, mais aussi des eaux souterraines (fig. 42a). Le sol sablonneux dans la partie nord de cette Sebkha est rouge brique avec une fine couche blanchâtre conduisant à la cristallisation du sel.

Les bordures ouest et nord de la dépression sont humides et présentent une formation végétale en forme de bande continue de 20 à 30 m de large. La partie nord de cette Sebkha a plusieurs poches d'eau permanentes, dont le fond a une texture sablonneuse et les bords ont des concrétions de sable et de sel (Qninba et al., 2009; Bennas et al., 2016;). L'eau dans ces poches est fournie par de petites résurgences, et la nappe affleure et humidifie le sol de la Sebkha, en particulier à ses frontières ouest et nord (Masoud et Koike, 2006). L'eau de pluie, rare à ces latitudes, est transportée vers la Sebkha via des ruisseaux, et les plus importants arrivent du côté nord. Cependant, à l'exception des poches permanentes au nord, le reste de la Sebkha n'a jamais été dans l'eau lors des visites sur place (Qninba et al., 2009). La Sebkha d'Imlili a deux caractéristiques qui ne peuvent pas être vues dans d'autres zones humides marocaines. Tout d'abord, cette Sebkha a conservé sa fonction hydrologique (une énorme Sebkha avec des poches d'eau salée permanentes où les poissons peuvent vivre) jusqu'à présent, une zone inexplorée du point de vue des études hydrologiques et hydrobiologiques (Bennas et al., 2016). Deuxièmement, bien qu'elle n'ait aucun lien avec la mer, l'eau de cette Sebkha est très salée et peut même être «hypersalin». Si le taux de salinité de la mer atteint 35 g / kg, la salinité de l'eau de la Sebkha d'Imlili varie entre 50 g / kg et 70 g / kg, ce qui est presque deux fois plus élevé que celui de l'eau de mer, du fait que «Le substrat est très salé et drainait l'eau saline du réseau souterrain» (Qninba et al., 2009). La Sebkha d'Imlili est une dépression continentale qui a perdu sa structure tabulaire sous l'influence marine. Cette Sebkha fait partie du bassin méso – cénozoïque de Tarfaya – Laayoune – Dakhla et comprend un ensemble de petits bassins qui sont allongés parallèlement à la côte et qui se sont formés pendant la période mésozoïque en direction marine du craton stable d'Afrique de l'Ouest; pendant ce temps, la partie sud-est de cette Sebkha est incluse dans le domaine d'Oulad Dlim, qui appartient à son tour à la crête de Réguibate située à l'extrême sud du Maroc (Qninba et al., 2012). Vers sa marge côtière, la région présente une formation miocène avec des variations latérales de faciès et d'épaisseur et se compose généralement de marnes sableuses, de lumachelles et de quartzites. L'évolution structurale méso – cénozoïque de cette région se manifeste principalement par sa tectonique fragile, qui est responsable de la répartition de la principal direction vers le nord: failles N 40 ° à N 50 ° et failles directionnelles N 70 ° plus petites, respectivement, qui ont influencé l'

évolution tectonique régionale plus au nord du bassin Tarfaya – Laayoune – Dakhla. Les caractéristiques géologiques de la Sebkhah d'Imlili profitent aux concentrations de roches et de minéraux industriels, tels que les calcaires lumachelliques, les marnes, les argiles, le gypse et les sables siliceux (Masoud et Koike, 2006).

4.2.5 Données spatiales, prétraitement et extraction des caractéristiques spectrales

4.2.5.1 Imageries optiques

Les images ont été sélectionnées en fonction de leur disponibilité pendant la période sèche entre avril et septembre pendant 10 ans à partir de 1984. Les entrées des paramètres spectraux ont été extraites d'une séquence de 90, 45 et 145 images Landsat-5 / TM de 1984, 1994, et 2004, respectivement, 107 images Landsat-8 / OLI de 2014 et 133 images Sentinel-2 de 2017 et 2019 (tableau 11). Un algorithme de script de masquage et de composition de nuage JavaScript personnalisé a été mis en œuvre dans GEE pour supprimer différents types de nuages et de bruits et pour générer une image multispectrale sans nuage. Les scènes « brutes » de GEE contiennent des images de réflectance à l'échelle avec des comptes numériques (DN). En utilisant les coefficients, la conversion des DN en radiance au niveau du capteur a été effectuée en utilisant une transformation linéaire (Chander et al., 2009; Bannari et al., 2016a). Nous avons utilisé la réflectance au sommet de l'atmosphère (TOA) ou l'algorithme de conversion de réflectance au niveau du capteur, une transformation linéaire qui couvre l'élévation solaire et la distance Terre-Soleil variable selon les saisons. Les bandes ont été utilisées pour extraire l'eau, la salinité du sol et les zones humides / sèches dans les bandes spectrales de réflectance solaire. Les images brutes de TM / Landsat-5 et OLI / Landsat-8 ont été stockées sous forme DN (QCAL), qui doivent être transformées en réflectance de surface explicite avant d'être traitées à l'aide de l'algorithme GEE. Toutes les images ont été soumises à un étalonnage radiométrique et à une correction atmosphérique. L'étalonnage radiométrique a transformé le QCAL original en rayonnement de TOA. Pour une longueur d'onde λ

spécifique, le rayonnement TOA L_λ et la réflectivité ρ_λ ont été calculées en utilisant les équations (12) et (13), respectivement, pour chaque bande sur la base des métadonnées des images (Chander et al., 2009).

$$L_\lambda = ((L_{MAX} - L_{MIN}) \times (Q_{CAL} - Q_{CALMIN}) / (Q_{CALMAX} - Q_{CALMIN})) + L_{MIN} \quad (12)$$

$$\rho_\lambda = (\pi * L_\lambda * d^2) / (ESUN_\lambda * \cos \theta) \quad (13)$$

où λ est la longueur d'onde de la bande, L_{MAX} est le rayonnement spectral mis à l'échelle à Q_{CALMAX} , L_{MIN} est le rayonnement spectral mis à l'échelle à Q_{CALMIN} , Q_{CALMAX} est la valeur de pixel calibrée maximale quantifiée (correspondant à L_{MAX}) en DN (255 pour TM et 65,535 pour OLI), Q_{CALMIN} est la valeur de pixel calibrée quantifiée minimale (correspondant à L_{MIN}) en DN (1 pour TM et OLI), et Q_{CAL} est la valeur de pixel calibré quantifiée en DN (Huang et al., 2012). Tous ces paramètres se trouvent dans le fichier de métadonnées (MTL) inclus dans les images TM / OLI. De plus, d^2 désigne la distance relative au sol relative Terre-Soleil, $ESUN_\lambda$ représente l'irradiance solaire exoatmosphérique et θ représente l'angle zénithal solaire en degrés.

Les cavités d'eau permanentes qui se trouvent dans la partie nord de la Sebkha d'Imlili sont caractérisées par une eau à haute salinité. Par conséquent, pour extraire les caractéristiques de ces cavités, nous avons développé un espace de caractéristiques 2D (indice d'eau, indice de salinité). Dans la plupart des situations, l'eau présente une réflectance de bande visible plus élevée que les bandes infrarouges (Liu et al., 2018; Wang et al., 2018). Les surfaces des objets non aqueux n'ont généralement pas cette similitude spectrale, en particulier dans les zones désertiques (Bannari et al., 2016b; Feyisa et al., 2014; Fisher et al., 2016; McFeeters, 1996; Hakdaoui et al., 2019; Hakdaoui et Emran, 2019; Xiong et al., 2018). Par conséquent, nous avons utilisé l'indice d'eau développé par Xiong (Xiong et al., 2018) pour optimiser la séparabilité des pixels eau et non-eau. Cet indice spectral est appelé ABWI normalisé, qui peut être obtenu à partir d'images TM (équation (14)), d'images OLI (équation (15)) et MSI (équation (16)).

$$ABWI_{TM} = \frac{(\rho_1 + \rho_2 + \rho_3) - (\rho_4 + \rho_5 + \rho_7)}{(\rho_1 + \rho_2 + \rho_3) + (\rho_4 + \rho_5 + \rho_7)} \quad (14)$$

où ρ_1 , ρ_2 , ρ_3 , ρ_4 , ρ_5 et ρ_7 représentent respectivement les réflectances des bandes bleue, verte, rouge, proche infrarouge (NIR), infrarouge moyen (SWIR1) et SWIR2.

$$ABWI_{OLI} = \frac{(\rho_1 + \rho_2 + \rho_3 + \rho_4) - (\rho_5 + \rho_6 + \rho_7)}{(\rho_1 + \rho_2 + \rho_3 + \rho_4) + (\rho_5 + \rho_6 + \rho_7)} \quad (15)$$

Où ρ_1 , ρ_2 , ρ_3 , ρ_4 , ρ_5 , ρ_6 et ρ_7 représentent l'aérosol côtier, les réflectances des bandes visibles, NIR, SWIR1 et SWIR2, respectivement.

$$ABWI_{MSI} = \frac{(\rho_2 + \rho_3 + \rho_4) - (\rho_8 + \rho_{11} + \rho_{12})}{(\rho_2 + \rho_3 + \rho_4) + (\rho_8 + \rho_{11} + \rho_{12})} \quad (16)$$

Où ρ_2 , ρ_3 , ρ_4 , ρ_8 , ρ_{11} et ρ_{12} représentent respectivement les réflectances des bandes bleue, verte, rouge, NIR, SWIR1 et SWIR2.

Divers indices de salinité spectrale ont été développés pour détecter et cartographier les objets salins (Douaoui et al., 2006; Penga et al., 2019; Chen et al., 2016a; Dwivedi et Rso, 1992; Masoud et Koike, 2006; Bouaziz et al., 2011; Dong et al., 2019). Par exemple, l'indice de salinité à différence normalisée (NDSI), qui a été développé à partir de SWIR1 pour les données Landsat (1,55-1,75) et SWIR2 (2,08-2,35), a été largement utilisé dans la littérature étant donné sa capacité à refléter le niveau de salinisation du sol (Douaoui et al., 2006; Dong et al., 2019). Cependant, cet indice devient inefficace lorsque le sol est recouvert de végétation (Chen et al., 2016a). Plusieurs études ont montré que l'indice de végétation par différence normalisée (NDVI) diminue progressivement avec une augmentation de la salinité du sol en surface (Bouaziz et al., 2011). Néanmoins, ce phénomène n'a pas été observé dans la zone d'étude car

la caractéristique la plus importante de la végétation résidait en présence d'une ceinture mixte (*Phragmites australis*, *Juncus rigidus* et *Arthrocnemum macrostachyum*) (Dong et al., 2019), qui mesure environ 30 m de large et est continue le long des bords humides des côtés ouest et nord de la partie nord de la zone humide prospectée. L'indice de salinité peut être obtenu à partir d'images TM (selon l'équation (17)), d'images OLI (équation (18)) et de MSI (équation (19)).

$$NDSI_{TM} = \frac{\rho_5 - \rho_7}{\rho_5 + \rho_7} \quad (17)$$

$$NDSI_{OLI} = \frac{\rho_6 - \rho_7}{\rho_6 + \rho_7} \quad (18)$$

$$NDSI_{MSI} = \frac{\rho_{11} - \rho_{12}}{\rho_{11} + \rho_{12}} \quad (19)$$

Les valeurs maximales et minimales de ces indices ont été calculées avant leur transformation en séquences non dimensionnelles et normalisées comme suit :

$$Index_{ND} = \frac{Index - Index_{min}}{Index_{max} - Index_{min}} \quad (20)$$

Où $Index_{min}$ est la valeur d'indice minimale, $Index_{max}$ est la valeur d'indice maximale et $Index_{ND}$ est la valeur d'index normalisée.

Pour l'extraction de cavités d'eau permanentes, nous avons développé un indice sur la base des propriétés de ces cavités, à savoir, leur capacité en eau, leur haute salinité et l'humidité de l'espace limitrophe.

Nous avons également représenté un histogramme bidimensionnel pour voir la dispersion du nuage de pixel et pour analyser l'espace spectral généré par les indices ABWI et NDSI (fig. 43a). Après avoir évalué les résultats de la régression statistique, nous avons constaté que ABWI et NDSI avaient une corrélation linéaire positive. L'équation 21 de la régression est :

$$NDSI = -79.97 + 1.67 \times ABWI \quad (21)$$




Figure 43. (a) Espace des caractéristiques formé par l'indice de l'eau utilisant toutes les bandes et l'indice de salinité par différence normalisée (ABWI, NDSI) et la ligne de régression de ce plan ; (b) Espace des caractéristiques formé par l'indice de polarisat

Le coefficient de corrélation est de 0,66 (fig. 43a), ce qui indique que la salinité du sol augmente avec l'humidité du sol. Le processus sol humide / sel du sol se reflétait clairement dans l'espace caractéristique (ABWI, NDSI).

L'indice de cavité d'eau salée (SWCI) a été calculé comme suit en utilisant des données radiométriques optiques :

$$SWCI = \sqrt{NDSI_{ND}^2 + ABWI_{ND}^2}, \quad (22)$$

où $NDSI_{ND}$ est l'indice de sel non dimensionnel obtenu à partir de l'équation (22), $ABWI_{ND}$ est l'indice d'eau non dimensionnel obtenu à partir de l'équation (22) et SWCI est l'indice de présence de cavité d'eau salée.

4.2.5.2 Imageries SAR

Le radar SAR est une forme active de télédétection qui illumine la cible et sert de capteur absolu qui ne dépend pas de la lumière du soleil. Contrairement à l'aspect réfléchi du spectre

électromagnétique, le rayonnement micro-ondes est vulnérable à trois facteurs, à savoir l'inclinaison de la surface, la rugosité et la constante diélectrique du matériau cible (Daniels et al., 2003; Blumberg, 1998; Elachi, 1987).

Les variables d'entrée radar SAR ont été produites à une résolution spatiale de 10 m (tableau 11) à partir d'une série de 211 images Sentinel-1 SAR GRD en bande C de niveau 1. Les images radar disponibles dans GEE étaient sur des orbites ascendantes et descendantes et ont été acquises en mode interférométrique (IW) avec des angles d'incidence moyens allant de 30 à 40. Les données ont ensuite été prétraitées à l'aide de la boîte à outils Sentinel-1 disponible sur la plateforme SNAP, qui peut effectuer des étalonnages des radiométries, l'aplatissement radiométrique du terrain, le filtrage du speckle et la correction de terrain Doppler de portée (Touzi et al., 2005).

L'indice le plus rapide et le plus utile qui peut être extrait des données SAR d'intensité est le MNDPI, qui est mesuré à partir de deux bandes VH et VV prises pour une image par les satellites Sentinel-1 entre le 10 avril et le 10 août en 2015 et 2019. Cet indice a été transformé et lissé en utilisant un filtre de réduction du speckle Lee 7×7 pixels affiné et l'équation (23).

$$\text{MNDPI} = \frac{VH-VV}{VH+VV} \quad (23)$$

Où VH et VV sont les bandes de polarisation verticales-horizontales et verticales-verticales obtenues à partir du capteur Sentinel-1. Les sorties de cet indice variaient de -1 à 1 . Étant donné que la VV dans la zone d'étude était généralement supérieure à VH, le MNDPI variait de $-0,95$ à 0 .

Le MNDPI a été choisi pour deux raisons. Premièrement, la permittivité de la matière sèche contrastait fortement avec celle de l'eau, et le MNDPI s'est avéré utile pour distinguer divers niveaux d'humidité du sol (Becker et Choudhury, 1988; Paloscia et al., 2018). Deuxièmement, MNDPI a simulé l'indice de différence de polarisation micro-ondes introduit dans (Chauhan et Srivastava, 2016; Owe et al., 2001; Jackson, 2002; Al-Jassar et Rao, 2010), mettant ainsi en évidence sa réactivité aux états d'humidité du sol (Al-Jassar et Rao, 2010). Cet indice avait également une capacité considérable pour améliorer la couverture terrestre basée sur le SAR et

la sensibilité à certains paramètres spécifiques qui caractérisent la biomasse de la végétation, l'épaisseur de la neige ou l'eau de neige équivalente (Al-Jassar et Rao, 2010).

Pour extraire des cavités d'eau permanentes avec une grande précision, nous avons développé un nouvel indice basé sur le spectre des propriétés passives radiométriques du capteur optique et la polarisation des propriétés radiométriques actives du capteur SAR.

Pour une étude plus approfondie, l'espace des caractéristiques le plus discriminant pour les cavités d'eau permanentes a été formé par deux indices. Le premier indice était le spectre de Sentinel-2 MSI, qui était un capteur optique passif radiométrique (SWCI), tandis que l'autre indice était le polarimétrique de Sentinel-1, qui était un capteur SAR GRD radiométrique actif à double polarisation en bande C (MNDPI). La figure 43 présente le diagramme de dispersion qui montre une relation linéaire positive significative entre SWCI et MNDPI. La droite de régression quantitative est représentée par l'équation (24):

$$SWCI = -1.79 + 0.64 \times MNDPI \quad (24)$$

Le coefficient de corrélation était de 0,87 (fig. 43b), ce qui suggère que lorsque de l'eau salée était présente dans les cavités permanentes, l'humidité de surface augmentait progressivement avec le MNDPI. La relation entre l'humidité de surface et la présence d'eau salée dans le trou de la cavité s'est clairement reflétée dans l'espace caractéristique (MNDPI, SWCI).

Nous avons combiné l'indice de polarisation radiométrique SAR (MNDPI) avec l'indice optique radiométrique (SWCI) pour former le nouveau SAR / Optic SWCI (SOSWCI), que nous avons utilisé pour extraire les trous remplis d'eau salée avec une équation de haute précision (25).

$$SOSWCI = \sqrt{MNDPI_{ND}^2 + SWCI_{ND}^2} \quad (25)$$

4.2.6 Fusion de données radar / optique

Les processus de fusion jouent un rôle crucial dans la télédétection en raison de leur capacité à améliorer la qualité visuelle et la traduction. Ces processus sont également connus sous le nom de processus d'amélioration spatiale de l'image où des images panchromatiques avec des résolutions spatiales élevées sont fusionnées avec des images multispectrales avec des résolutions spectrales relativement élevées pour produire des images multispectrales avec des résolutions spatiales et spectrales élevées (Abdikan, 2018). Outre l'imagerie optique, le radar a également été couramment utilisé dans les zones boisées, urbaines et agricoles. Plusieurs études forestières montrent que la bande C est très résistante aux feuilles et aux petites branches et a un VH supérieur au VV et une polarisation horizontale à transmission horizontale HH. Cependant, le radar a rarement été utilisé dans les régions arides et désertiques (Evans et al., 1998; Barbouchi et al., 2014; El-Zeiny et Effat, 2017). Les capteurs optiques définissent la composition chimique d'un objet de surface, tandis que la diffusion micro-ondes est influencée par les éléments structurels et la rugosité de la surface de l'objet. La polarisation SAR est un facteur déterminant dans la détection de l'eau (El-Zeiny et Effat, 2017; Dobson et Ulaby, 1998; Altese et al., 1998). Des études antérieures (Doubková et al., 2012; Haas, 2010; Hammam et Mohammed, 2018) ont montré que les images polarisées HH sont plus adéquates pour la détection de l'eau que les images polarisées VV ou croisées VH (Baghdadi et al., 2002) parce que la polarisation HH produit la discrimination la plus élevée dans les valeurs de rétrodiffusion entre les sols secs et humides et entre les sols lisses et rugueux. Étant donné que l'image disponible dans cette étude avait une polarisation d'intensité VV et VH, nous avons utilisé l'indice MNDPI, qui s'est avéré utile pour discriminer différents niveaux d'humidité du sol (Becker et Choudhury, 1988; Paloscia et al., 2018). MNDPI a été sélectionné à la place de VV ou VH pour le processus de fusion avec Sentinel-2 MSI multispectral. Trois algorithmes de fusion populaires, à savoir, l'analyse en composantes principales (ACP) (Zoka et al., 2018; Kumar et al., 2017), la saturation de la teinte d'intensité (Liu et al., 2015; Chavez et al., 1991; Siddiqui, 2003) et la transformée en ondelettes (Zhou et al., 1998) ont été utilisées pour combiner l'information multispectrale contenue dans l'image Sentinel-2 MSI avec l'information polarimétrique contenue dans l'image SAR Sentinel-1 GRD. Le meilleur résultat

a été obtenu à partir de l'algorithme de fusion ACP. L'ACP est une procédure statistique qui convertit un ensemble multivarié de divers paramètres corrélés en un ensemble de combinaisons linéaires non corrélées des variables d'origine (Kumar et al., 2017). Pour l'image Sentinel-2 MSI de 2017, la première bande 1 de la composante principale (PC1) a été remplacée par l'image de l'indice polarimétrique mono-bande (c'est-à-dire la bande MNDPI), qui a été mise à l'échelle pour correspondre à la bande PC1 pour éviter de fausser les données spectrales. Une transformation inverse a ensuite été appliquée. En utilisant la méthode de convolution bicubique, les données multispectrales ont été automatiquement rééchantillonnées à la taille des pixels haute résolution (10 m). Après la fusion, l'image résultante contenait les caractéristiques d'une image polarimétrique (c'est-à-dire le canal MNDPI) et la haute résolution spatiale et spectrale de Sentinel-2 MSI.

4.2.7 Classification par approche machine learning en utilisant l'algorithme Random Forest (RF) au sein de GEE

Les forêts aléatoires (RF) sont des algorithmes de classification Machines Learning non-paramétrique. L'approche RF est une technique de classification relativement nouvelle basée sur l'apprentissage automatique d'ensemble et a été de plus en plus utilisée comme classificateur de choix pour la télédétection de différents types de zones humides (Noi et Kappas, 2017 ; Berhane et al., 2018b). L'approche RF, comme celui des arbres de décision (DT) ou celle basée sur des règles (RB), est non paramétrique, robuste aux écarts par rapport aux distributions normaux qui constituent la principale contrainte des méthodes paramétriques, et peut être utilisée à la fois pour les classifications et les régressions, ainsi que pour déterminer l'importance variable (Kotsiantis, 2007; Belgiu et Dragut, 2016). Ainsi, la RF présente de nombreux avantages de la classification DT et RB tout en surmontant plusieurs limitations, telles que le surapprentissage (Breiman, 2001). Les erreurs de biais et de variance peuvent affecter les approches DT et RB, tandis que RF évite les deux erreurs grâce à la sélection

aléatoire de variables d'entrée-prédicteur et à l'utilisation de différents sous-ensembles du même ensemble de données d'apprentissage (Breiman, 2002).

Les RF ont une excellente efficacité de calcul en raison de leur agrégation Bootstrap, qui crée un vote majoritaire et fait la moyenne d'une grande collection d'arbres de décision décorrélés pour produire une prédiction ou une sortie classée. Les RF démontrent également une précision de classification prometteuse pour les données multisources dans le domaine de la télédétection (Gislason et al., 2006; Belgiu et Dragut, 2016), étant donné que les données multisources sont trop complexes pour être classées à l'aide d'une règle de décision paramétrique (Tian et al., 2016). Plusieurs études ont également mis en évidence les avantages de la RF dans la classification de l'occupation du sol (Gislason et al., 2006; Corcoran et al., 2013). Plus précisément, cet algorithme permet aux utilisateurs de choisir le nombre d'arbres, le nombre de variables que chaque arbre utilise pour les fractionnements, la meilleure variable à fractionner et les règles de fractionnement et d'arrêt (Belgiu et Dragut, 2016; Corcoran et al., 2013; Van Beijma et al., 2014). Les RF sont ajustés en changeant le nombre de variables utilisées par chaque arbre et en prédisant un ensemble de validation. Dans notre schéma de validation croisée, le modèle a été formé sur 90% de l'ensemble de données et validé en utilisant 10% de l'ensemble de données. GEE fournit de nombreux algorithmes d'apprentissage automatique, y compris RF.

Figure 44 présente un aperçu des principales étapes méthodologiques utilisées dans ce travail. Premièrement, nous avons prétraité les jeux de données de réflectance des satellites dans GEE pour extraire et suivre l'évolution des indices d'eau (ABWI) et de salinité (NDSI) de 1984 à 2019 tous les 10 ans. Deuxièmement, nous avons défini un nouvel indice pour la détection du signal des cavités d'eau permanente de la Sebkha en étudiant la corrélation entre les indices de salinité et de l'eau. Ce nouvel indice a mesuré le signal de présence de cavité rempli d'eau salée, que nous avons appelé SWCI, et a été utilisé pour le suivi de la présence ou de l'absence d'eau salée dans les cavités étudiées de 1984 à aujourd'hui. Troisièmement, nous avons extrait un indice d'humidité du sol (MNDPI) dans la GEE à partir des images Sentinel-1 et 2 SAR pour suivre l'humidité de surface de 2015 à aujourd'hui. Cet indice polarimétrique a montré une forte

corrélation avec le SWCI optique, ce qui nous permet de définir un autre indice appelé SOSWCI qui combine les propriétés diélectriques avec les propriétés spectrales. Le SOSWCI n'a été appliqué que pour les images optiques et radar obtenues en avril 2017, qui correspondaient à la date de collecte des données in-situ utilisées pour la validation. Ces images ont également été utilisées pour fusionner des données radiométriques passives et actives en une seule image que nous avons utilisé pour explorer le mode de fonctionnement hydrologique de la Sebkha d'Imlili. La dernière image obtenue par fusion a été utilisée dans le processus de classification non paramétrique avec RF comme méthode de Machine Learning.




Figure 44. Aperçu schématique de l'approche méthodologique suivie dans ce travail (Workflow).

4.3 Résultats

Cette section présente les résultats obtenus à partir des données passives radiométriques optiques et active SAR. Nous commençons par le suivi de la salinité du sol de la Sebkha d'Imlili et étudier les changements de NDSI de 1984 à aujourd'hui. Nous avons ensuite surveillé l'humidité de surface de la Sebkha en étudiant les changements dans ABWI. Nous avons finalement surveillé l'état humide / sec des cavités d'eau salée de Sebkha en utilisant un index nouvellement défini, le Salt Water Cavity Hole Index (SWCHI), et en nous référant aux données optiques. Nous avons ensuite présenté les résultats obtenus à partir des données radiométriques SAR actives. Dans ce domaine actif, nous avons utilisé MNDPI pour surveiller les changements dans l'état d'humidité de surface, et nous avons combiné cet indice avec un autre indice extrait du domaine optique pour obtenir SOSWCI, qui mélangeait radiométrie passive et radiométrie active. SOSWCI ne sera pas utilisé pour la surveillance mais plutôt pour augmenter la précision sur la connaissance de l'état humide / sec des cavités d'eau salée de Sebkha en 2017, au cours de laquelle les données de terrain ont été collectées. Un travail basé sur la fusion du radar et de l'optique a également été réalisé pour cartographier le réseau souterrain et comprendre le mode de fonctionnement hydrologique de la Sebkha.

4.3.1 Cartographie des changements des caractéristiques environnementales de la Sebkha d'Imlili à partir de données optiques

4.3.1.1 Surveillance de la salinisation de surface des sols de la Sebkha d'Imlili

Nous avons obtenu les données de salinisation du sol de la Sebkha d'Imlili pour les années 1984 à 2019 à partir des images Landsat-5 TM pour les années 1984, 1994 et 2004 respectivement (fig. 45 a, b, c), et l'image Landsat-8 OLI pour 2014 (fig. 45d) puis dérivé des informations sur la salinisation du sol de Sentinel-2 MSI (fig. 45e). Nous avons également étudié les variations spatiales et temporelles de la salinisation des sols entre 1984 et 2019.




Figure 45. Suivi du NDSI de 1984 à 2019 (a-e) et les points vert correspondant à la distribution spatiale de la salinisation du sol mesurées sur le terrain, et (f) corrélation entre le NDSI extrait des images Sentinel-2 MSI 2017 et les mesures de salinité des

La corrélation entre les points d'échantillonnage des cavités d'eau salée (correspondant à la teneur en sel mesurée sur le terrain collecté du 14 avril 2017 au 16 avril 2017 lors d'une enquête

sur le terrain des sites) et les attributs NDSI de l'image Sentinel-2 MSI a été analysée. La corrélation de la distribution spatiale R2 entre la salinité mesurée sur le terrain de ces cavités et l'indice NDSI de télédétection extrait à partir des données Sentinel-2 MSI était de 0,86 (fig. 45 f).

L'indice de salinisation du sol de Sebkha d'Imlili a été reclassé en quatre classes pour les années 1984 à 2019 (fig. 46 a – e) : absence de salinisation, salinisation légère, salinisation modérée et salinisation extrême selon le niveau de classification de salinisation des sols trouvé dans la littérature (tableau. 12). La figure 46 a-e montre une augmentation constante de la zone de sols extrêmement salinisés de 1984 à 2019, tandis que la figure 46f montre que les cavités avec une salinisation sévère étaient presque absentes de 1984 à 1994 (fig. 46 f). Le nombre de cavités avec une salinisation sévère a également augmenté de 1994 à 2014 (fig. 46 f) et s'est stabilisé sur un état de salinisation sévère entre 2014 et 2019 (fig. 46 f).

Tableau 12. Classification de la salinisation normalisée des sols selon la littérature (Azabdaftari et Sunar, 2016)

NDSI	Non-salinisation	Salinisation légère	Salinisation modérée	Salinisation sévère
Landsat	$\leq 0,2$	0,2–0,4	0,4–0,8	$\geq 0,8$




Figure 46. a - e Distribution des classes spatiales de salinisation du sol de 1984 à 2019 par rapport à la salinisation du sol mesuré sur le terrain et reclassé en deux classes, et (f) Histogramme de salinisation des cavités d'eau salée extraites du NDSI reclassé

4.3.1.2 Suivi des états d'humidification/sécheresse des cavités d'eau permanente de la Sebkha à l'aide de l'indice SWCHI

Nous avons suivi les états d'humidification et sécheresse des cavités permanentes d'eau salée de la Sebkha d'Imlili de 1984 à 2019 en calculant SWCHI et le reclassifiant en quatre classes selon l'état d'humidité du sol (c.-à-d. cavités d'eau salée sèches, moyennement sèches, modérément humides et très humides) à partir des images Landsat-5 TM prises en 1984, 1994 et 2004 (fig. 47 a – c), l'image Landsat-8 OLI prise en 2014 (fig. 47 d) et Sentinel-2 MSI (fig. 47e). Les figure 8a et 8f montre que toutes les cavités de la Sebkha étaient sèches en 1984, à l'exception de certaines cavités qui étaient modérément humides. Dans la figure 47 classe les sols d'Imlili Sebkha de 1984 à 2019 (fig. 47 a – e). La figure 47f qui représente un histogramme et qui montre que la fréquence des cavités d'eau salée très humides a augmenté régulièrement de 1984 à 2019, elle montre aussi un changement brusque dans la fréquence des cavités d'un état sèche à très humide après 1994, suivi d'une stabilisation autour d'un état modérément humide à très humides de 2004 à 2019 (fig. 47 c – e et figure 47f). Cependant, en 2019, le nombre de cavités très humides a légèrement diminué par rapport à l'année 2017 (fig. 47f).




Figure 47. (a - e) Signal SWCI reclassifié en quatre classes de cavités d'eau salée sèches à très humides de 1984 à 2019 par rapport à la profondeur des cavités d'eau salée mesurées sur le terrain et reclassées en deux classes, et
(f) Histogramme des états sec /

4.3.2 Cartographie des changements des caractéristiques environnementales de la Sebkhia d'Imlili à partir des données SAR

Suivi de l'état d'humidité des cavités d'eau salée à l'aide du MNDPI

Les informations sur l'humidité du sol de la Sebkhia d'Imlili ont été évaluées en calculant l'indice MNDPI à partir de l'image Sentinel-1 SAR GRD bande C de niveau 1 pour les années

2015 à 2019. Les profils d'humidité spatiale et temporelle du sol à partir du signal MNDPI ont été analysés. La carte d'humidité a été générée en reclassifiant le signal MNDPI en quatre classes (fig. 48 a – e), et les histogrammes de fréquence des états d'humidité des cavités d'eau salée ont été extraits à partir du MNDPI reclassé (fig. 48f). Les résultats obtenus à partir des images radar étaient très précis car le signal radar était très sensible à la géomorphologie du sol. Près des cavités d'eau, le radar a réussi à détecter un microrelief comme indiqué par les points rouges sur la figure 48 a – e. De plus, l'indice MNDPI a montré une sensibilité élevée à l'humidité, comme l'indique son signal maximal au niveau des cavités d'eau. Ces deux facteurs ont amélioré l'efficacité de détection radar des cavités d'eau, rendant ainsi nos résultats plus précis que ceux obtenus par les capteurs optiques. Nous avons également observé un comportement du SAR similaire à celui obtenu par les capteurs optiques en ce qui concerne la détection de l'état d'humidité des cavités de 2015 à 2018. De même pour l'année 2019, nous avons observé pour le SAR une diminution significative des puits les plus humides (fig. 48f).




Figure 48. (a – e) Carte d'humidité obtenue à partir de la reclassification du signal MNDPI en quatre classes de non-humidité à forte humidité des trous d'eau de 2015 à 2019 par rapport à la profondeur des cavités d'eau salée mesurée sur le terrain et reclassée en deux classes, et (f) les statistiques de l'état d'humidité des cavités d'eau salée extraites du MNDPI.

4.3.3 Collaboration SAR / Optique pour cartographier l'état d'humidité de surface des cavités d'eau salée pour l'année 2017

4.3.3.1 Cartographie des états humides / sèches des cavités à l'aide de SOSWCI

Pour détecter avec précision les cavités humides ou sèches, nous avons développé SOSWCI, qui combine les indices spectraux d'humidité (ABWI) et de salinité (NDSI) extraits des images optiques avec l'indice d'humidité (MNDPI) extrait de l'intensité de polarisation radiométrique SAR des images radar. Étant donné que les images radar et optiques doivent être prises à la même date, nous avons sélectionné 2017, au cours de laquelle les données ont été collectées sur le terrain. Comparé aux résultats obtenus à partir de l'indice d'humidité radar seul (fig. 48 f), le résultat obtenu à partir de l'indice combinant radar et optique était plus proche des résultats obtenus sur le terrain (fig. 49. c, d).




Figure 49. a) Le signal Sar / Optic Saltwater Cavity Index (SOSWCI) reclassé en cinq classes à partir de 2017 par rapport à la profondeur des cavités d'eau salée mesurées sur le terrain et reclassé en deux classes ; b) états secs / humides des cavités d'eau salée p

4.3.3.2 Cartographie du réseau hydrographique souterrain à partir de l'image fusionnant les données radar et optiques

La figure 50 présente un aperçu de l'image Sentinel-2 MSI (fig. 50a) et du SAR Sentinel-1 fusionné avec les données Sentinel-2 MSI (fig. 50b). La différence entre l'image produite par les données de réflectance et la rétrodiffusion fusionnée avec la réflectance est que la topographie du substratum rocheux a été légèrement enfouie, et le radar a réussi à mettre en évidence le réseau hydrographique sous le sable, que le capteur optique seul ne peut pas voir en raison de sa nature d'interaction de surface (Blumberg, 1998; Elachi, 1987). Cette différence peut être attribuée au fait que la rétrodiffusion du SAR est une interaction de volume à laquelle s'ajoute la pénétration de l'onde radar dans le sol. Ce qui permet d'avoir des informations sur

les caractéristiques du sous-sol. Les mécanismes hydrologiques et hydrogéologiques de la Sebkhha d'Imlili peuvent être attribués à ses aquifères, qui sont parmi les aquifères profonds les plus importants de tout le Sahara.




Figure 50. (a) Composition colorée RVB de Sentinel-2 MSI, (b) le SAR Sentinel-1 fusionné avec l'image Sentinel-2 MSI montrant le réseau hydrographique enterré (bleu) mis en évidence par les données radar et le réseau hydrographique superficiel (jaune) mis en évidence.

4.3.3.3 Classification par approche machine learning en utilisant l'algorithme RF sous la GEE sur un ensemble de données intégrées multibandes (multicapteur, multisource, multipolarisation et multiindices)

Pour atteindre notre objectif de recherche, nous avons créé un ensemble de données multibande optimisé de 11 bandes comprenant 6 bandes de réflectance, 2 bandes SAR polarimétriques (VV et HV) et les 3 indices extraits du SAR et de l'optique (MNDPI, NDSI et ABWI). Compte tenu des tests de classification initiaux et de la quantité importante de références qui mettent en évidence l'importance des RF en télédétection (Berhane et al., 2018a; Berhane et al., 2018b; Van Beijma et al., 2014; Corcoran et al., 2013; Belgiu et Dragut, 2016), nous avons utilisé un modèle de classification RF disponible sur la plate-forme GEE. Contrairement à l'arbre optimal

unique construit à l'aide de l'ensemble des données d'apprentissage et de toutes les variables prédictives des approches DT et RB, la RF crée un ensemble d'arbres qui fournissent chacun un « vote » pour sélectionner la meilleure approche de classification. Autrement dit, l'appartenance à une classe dans un DT est décidée par un seul arbre, tandis que la majorité des votes des assemblages d'arbres construits par RF décident de l'affectation de classe d'un pixel donné. Concernant l'architecture du modèle RF, le nombre d'arbres de décision a été fixé à 500 en utilisant 80% de tous les échantillons, soit 4012 échantillons ont été utilisés pour former le modèle RF. Pour le résultat, nous avons effectué une évaluation de la précision basée sur des échantillons de référence et une évaluation de la cohérence basée sur des images multisources et des données de vérités terrain. L'évaluation de la précision basée sur des échantillons était basée sur des échantillons de vérification précédemment distribués au hasard, et une série d'indices de précision a été obtenue en construisant une matrice de confusion (tableau 13). En se référant à l'image satellite de très haute résolution.

La première étape du processus RF a été de tirer un échantillon bootstrap de taille $N=4012$ à partir des données d'apprentissage (fig. 51). Lorsqu'un échantillon est entré dans le modèle RF, chaque arbre de décision effectue une évaluation distincte pour déterminer la catégorie à laquelle l'échantillon doit appartenir. Une fois qu'un arbre RF a atteint les informations d'amorçage pour chaque échantillon, les étapes suivantes ont été répétées pour chaque nœud d'arbre: (1) Les m variables ont été sélectionnées au hasard parmi les p variables (soit 11 néocanaux), et la meilleure variable de point de partage a été choisie parmi elles; (2) Le nœud a été séparé en deux nœuds filles; (3) Pour la classification, l'étiquette qui est la plus souvent sélectionnée est finalement considérée comme étiquette de l'échantillon.




Figure 51. (a) Résultat de la classification par RF appliquée aux 11 ensembles de données multibandes de 2017, et (b) la même image superposée à la position des cavités permanentes d'eau salée de la Sebka d'Imlili.

Le tableau 13 fournit les estimations de précision pour le modèle complet. Les colonnes montrent les étiquettes des catégories de thème représentant les prédictions du modèle RF (pixels classés par classe), les lignes montrent les données de référence validées sur le terrain (pixel de référence pour chaque classe) et $n_i +$ et n_{+j} représentent les totaux des lignes et colonnes précédentes, respectivement. De plus, O_{er} désigne l'erreur d'omission, C_{er} désigne l'erreur de commission, U_i indique la précision de l'utilisateur, P_i dénote la précision du producteur, et OA dénote la précision globale. Pour la plupart des eaux libres, des sols humides et des sols secs (y compris les sols très humides et les sols très secs), la matrice a montré une précision relativement élevée pour les consommateurs et les producteurs.

Tableau 13 Nombre de pixels de la matrice d'erreur avec une précision globale (OA).

Référence (Ground Thruth)	Classe							Évaluation de la précision%			
	1	2	3	4	5	6	n_{+j}	O_{er}	U_{je}	P_{je}	OA
1	77	2	2	0	1	2	84	8.3	91,7	96,2	93,2
2	0	74	1	0	2	0	77	3.9	96	92,5	
3	2	1	73	1	1	0	78	6,4	93,6	91,2	
4	0	1	2	76	1	0	80	8	92	95	
5	1	1	1	2	74	2	81	8.6	91,4	92,5	
6	0	1	1	1	1	75	79	5	95	95	
n_{+j}	80	80	80	80	80	97	479				
C_{er}	3,75	7,5	8.75	5	7,5	5					

La précision de catégorisation moyenne obtenue en utilisant ce sous-ensemble de données était de 93,20% (tableau 13), ce qui est une valeur très appropriée. Les pourcentages de classifications correctes des pixels en tant que cavité avec eau libre, sol très humide, sol modérément humide, sol légèrement humide, sol sec et sol très sec étaient de 96,2%, 92,5%, 91,2%, 95%, 92,5% et 95 %, respectivement. La valeur du coefficient d'accord pour cette classification était de 94,5%, le désaccord de quantité était de 2,1, le désaccord de répartition était de 2,77 et le désaccord total était de 4,2. Ces valeurs suggèrent que la classification RF et les données de vérité terrain recueillies montrent un bon accord.

4.4 Discussion

La Sebkha d'Imlili est une structure d'eau douce originale au Sahara qui a connu des événements tropicaux historiques dans l'extrême sud du Maroc. Cette Sebkha représente une section humide et dynamique d'une ancienne rivière qui a été isolée et asséchée en raison de la désertification de la région au cours des mille dernières années (Qninba et El Agbani, 2018). La partie nord de de Sebkha d'Imlili compte 161 poches d'eau permanentes. Bien que l'eau dans cette zone soit salée et hypersaline, les poches contiennent de la flore et de la faune marines et l'eau douce stagnante et coulante (Qninba et al., 2009). Nous avons d'abord analysé nos résultats obtenus à partir des traitements des images spatiales optique et radar SAR sur les niveaux de salinité des sols et les conditions humidification / sécheresse des surfaces autour des poches d'eau permanentes que nous avons comparé aux données de terrain.

4.4.1 Suivi de la salinité du sol et des états d'humidification / sécheresse des surfaces autour des cavités d'eau permanentes

4.4.1.1 Suivi de la salinité du sol de la Sebkhah d'Imlili

Plus la salinité d'un sol augmente plus sa réflectance est importante (Abbas et al., 2013; Bannari et al., 2007). Par contre, l'augmentation de la salinité du sol affecte tout le spectre de la réflectance et le domaine SWIR (Masoud et al., 2006; Abbas et al., 2013; Bannari et al., 2008). Les satellites à capteur SWIR peuvent capturer facilement les caractéristiques hautement réfléchissantes des sols très salins et jouer un rôle fondamental dans le suivi et la surveillance à distance d'une large zone de salinisation des sols (Masoud et al., 2006). La figure 6a–c montre que la salinité varie largement d'une cavité à l'autre même lorsque ces cavités sont situées à proximité les unes des autres et même si seul un petit nombre de cavités ont une salinité sévère. Le niveau de salinité est devenu uniforme et sévère dans les années qui ont suivi (fig. 47d, e). Ces résultats sont en accord avec ceux obtenus par Qninba et Emran (Qninba et El Agbani, 2018; Emran, 2016).

4.4.1.2 Suivi des états d'humidification / sécheresse des surfaces autour des cavités d'eau permanentes

Les résultats du suivi des états d'humidification / sécheresse des surfaces autour des cavités d'eau permanentes peuvent être validés en utilisant des données météorologiques pour les années 1984 à 2004. Étant donné que les images pour les années 2015 à 2019 étaient disponibles sur GEE, nous avons utilisé ces images pour valider nos résultats pour l'optique et vérifier les performances des données radar.

Selon l'évolution des précipitations au cours des quatre dernières décennies (1971-2019), le désert du Sahara a connu un long épisode sec de 1971 à 1993 et une période de récupération par la suite. Pendant ce temps, entre la fin des années 1990 et 2010, les précipitations sur le désert du Sahara ont montré une reprise évidente avec une tendance à la hausse de 15,2% par

décennie. La variabilité temporelle des précipitations dans ce désert est comparable à l'anomalie globale des précipitations dans la région, ce qui signifie que le climat au Sahara a été influencé par des forces anthropiques qui sont responsables du changement global du niveau des précipitations (Trape, 2009). Une précipitation inhabituellement extrême a également été observée dans le désert du Sahara au milieu des années 90, et nous avons examiné ces changements brusques en conséquence. La figure 52 a,b montre qu'après ce changement brusque, le désert du Sahara a connu une augmentation des précipitations. Des changements abrupts significatifs des précipitations ont également été enregistrés au cours des étés 1992 et 1993 (Sindikubwabo et al., 2018), et ces changements ont été suivis de précipitations fréquentes, comme le montre la figure 53. Ces données météorologiques concordent bien avec les résultats obtenus à partir du suivi des états d'humidification / sécheresse des surfaces autour des cavités d'eau permanentes (fig. 48 f).




Figure 52. (a) Graphique des précipitations de 1985 à 2019 généré à l'aide de la plateforme ClimateEngine, et (b) Graphique des précipitations annuelles moyennes obtenu à partir de (Sindikubwabo et al., 2018).




Figure 53. Variation temporelle de l'anomalie interannuelle des précipitations estivales (%) entre 1971 et 2010

La figure 55 montre les états d'humidification / sécheresse des surfaces autour des cavités d'eau permanentes de 2014 à 2018, obtenu dans la plateforme GEE. La cavité d'eau indiquée par le cercle jaune était sèche en 2014, légèrement sèche en 2015, modérément humide en 2016, très humide en 2017 et modérément humide en 2018. Pendant ce temps, la cavité d'eau indiquée par le cercle rouge était très humide en 2014, légèrement humide en 2015, sec en 2016, moyennement sec en 2017 et sec en 2018.




Figure 55. Suivi de quatre cavités d'eau salée en jaune, vert, bleu et rouge de 2014 à 2018.

4.4.2 Origine des cavités permanentes d'eau salée de la Sebkha d'Imlili

Dans cette étude, une double polarisation des satellites SAR a été combinée avec des données multispectrales pour extraire les caractéristiques du terrain de la surface de la Sebkha, y compris leur distribution granulométrique et la composition de la roche dominante. Pendant ce temps, la discrimination des objets selon cette double polarisation fournit des informations relativement précises concernant la rugosité, la taille des particules (Daniels et al., 2003; Blumberg, 1998). Par conséquent, dans l'étude de la rugosité du sol, la taille des grains, la teneur en humidité volumétrique et l'homogénéité, le radar polarimétrique à double polarisation peut être combiné avec des données multispectrales et utilisé pour distinguer différents types de sol et les différents états d'humidité du sol dans la Sebkha d'Imlili (Daniels et al., 2003; Blumberg, 1998). La présence de manière permanente de l'eau dans les cavités d'eau salée peut être attribuée à une combinaison de variabilités géologiques, hydrogéologiques et temporelles des précipitations sur le désert du Sahara. Les phénomènes de précipitation ont permis une alimentation continue de la nappe superficielle sous-jacente, en particulier pendant les épisodes pluvieux (Blumberg, 1998). Cette eau circule dans l'interface couche perméable / couche imperméable, assurant le remplissage quasi permanent des poches. La Sebkha représente la sortie et le point le plus bas d'un grand réseau hydrographique souterrain et superficiel. L'hypersalinité des cavités d'eau permanentes peut être attribuée à la salinité du substrat et au drainage de l'eau salée du réseau souterrain (Qninba et El Agbani, 2018; Emran, 2016). Compte tenu de sa grande superficie, la zone d'étude reçoit un grand volume d'eau de pluie, mais le taux

d'infiltration dans le sous-sol joue contre le ruissellement de surface, empêchant ainsi les inondations d'atteindre la Sebkha. Dans ce cas, le sol légèrement incliné de la Sebkha améliore la visibilité du ruissellement le long des canaux, ce qui est à peine visible en topographie et en imagerie optique. L'origine des cavités d'eau salée peut être attribuée à la présence de failles sous la surface de la Sebkha, tandis que leur forte salinité peut être attribuée aux phénomènes de lixiviation (Qninba et El Agbani, 2018; Emran, 2016).

Dans cette recherche, nous avons testé la capacité d'un radar Sentinel-1 dual polarimétrique (deux polarisations), à détecter et surveiller les caractéristiques du terrain d'intérêt de la Sebkha d'Imlili. Nous pensons que cette approche sera améliorée par la diversité de polarisation des données polarimétriques complètes (Full polarimétrique), leur capacité d'imagerie polarimétrique, leur mode haute résolution et leur capacité à regarder de chaque côté de la piste satellite. Cette approche peut également fournir des informations utiles qui peuvent faciliter une cartographie détaillée et précise des états d'humidité du sol, de la dynamique spatiale et de l'état des cavités d'eau permanentes dans la partie centrale de la Sebkha, des caractéristiques de la végétation sur les bords et des processus qui façonnent activement cet environnement.

4.4.3 Proposition du flux de travail pour le développement d'un JN d'alerte précoce pour la préservation des écosystèmes naturels

La création d'un JN pour permettre la préservation des écosystèmes naturels implique l'intégration de la modélisation de la réalité à l'échelle de l'écosystème naturel entier, de la cartographie 3D et de la modélisation de cet environnement. Le modèle de préservation proposé résultant peut être utilisé pour l'analyse, la simulation, la visualisation et la communication. Pour commencer dans ce flux de travail, nous utilisons un logiciel de modélisation de la réalité et de cartographie 3D pour générer un maillage de réalité 3D haute résolution à l'échelle de l'écosystème en utilisant des photos superposées de drones et des images au sol, complétées par des scans laser au sol et mobile en utilisant par exemple Leica Pegasus Backpack Solution mobile pour capturer la réalité qui est une solution 3D mobile portative. Le modèle / maillage de capture de la réalité est classifié spatialement, ce qui signifie

que les parties importantes de cet écosystème, les Sebkhas, les cavités d'eau salée et autres éléments du paysage de celui-ci maillé sont liés à des données SIG sous-jacentes et applicables. Le modèle de réalité est également nativement prêt pour l'exploitation, avec une résolution et une évolutivité suffisante pour zoomer sur une zone et effectuer des travaux écologiques directement hors du maillage. Et surtout, le modèle de réalité comprend des données numériques de terrain, ce qui est fondamental pour toute simulation à faire pour cet écosystème. Ensuite, un modèle de préservation de l'écosystème est créé en mettant en place un maillage de calcul pour la zone d'intérêt, que ce soit l'écosystème entier ou seulement une fraction importante que nous voulons étudier de celle-ci. Ce maillage de calcul est ensuite rempli de données utilisées pour les simulations et l'analyse de cet écosystème fragile. Les données numériques du terrain peuvent être extraites directement du modèle de capture de la réalité pour fournir des données de surface précises pour le logiciel de modélisation des changements qui peuvent détériorer ou améliorer l'écosystème ainsi qu'un contexte visuellement réaliste pour visualiser les simulations de changement de l'écosystème. Le modèle issu de la capture de réalité peut également être utilisé pour identifier les objets importants, les espèces rares, les arbres et d'autres informations requises par le modèle de préservation. Le modèle est actualisé en continu à partir de plusieurs sources - telles que des capteurs IoT, des levés continus ou des mises à jour SIG - pour représenter les conditions actuelles.

4.5 Conclusions

L'intégration des technologies de l'information dans les domaines de l'accessibilité des données, du Cloud Computing et de l'apprentissage automatique offre de nombreuses possibilités d'applications du géospatiales aux niveaux temporel et spatial. Notre étude s'est concentrée sur la cartographie, la surveillance et le suivi des conditions des états d'humidification / sécheresse des surfaces autour des cavités d'eau permanentes qui représente un écosystème de zones humides sahariennes très vulnérables. Les résultats mettent en

évidence les fonctions des cavités d'eau salée dans la Sebkha et les valeurs écologiques de cette zone, qui sont largement inexplorées dans la littérature.

L'utilisation d'un flux de travail géospatial basé sur le cloud nous a permis de cartographier, de surveiller et de suivre efficacement et rapidement les cavités d'eau salée de la Sebkha d'Imlili. Les résultats montrent non seulement la valeur d'une surveillance et d'un suivi à long terme pour la protection efficace et durable de ces écosystèmes fragiles, mais nous aident également à comprendre la fonction de ces zones humides sahariennes. Le flux de travail géospatial nous a également permis de détecter les fluctuations temporelles des conditions d'humidification / sécheresse de surface autour des cavités d'eau permanentes, ce qui est crucial pour comprendre comment ces zones fonctionnent et pour trouver des moyens de protéger ces zones vulnérables à un large éventail de modifications environnementales et hydrologiques d'origine humaine associées à la croissance démographique, à l'urbanisation et à l'augmentation des activités touristiques dans cette région classée Ramsar.

Enfin dans les perspectives de ce travail, nous pensons mettre en pratique le développement d'un JN pour les alertes précoces et pour la préservation des écosystèmes rares et fragiles.

Chapitre 5 : Cartographie mobile, apprentissage automatique et jumeau numérique pour la surveillance et la maintenance de l'état de santé des ponts : Cas du pont Mohammed VI au Maroc

5.1 Introduction

La transformation numérique des infrastructures est en cours, qu'il s'agisse d'un site de projet, d'un bâtiment intelligent, d'une usine, d'un service public ou d'une ville entière. Les organisations qui travaillent dans le secteur des infrastructures qui planifient, conçoivent, construisent et exploitent des infrastructures peuvent maintenant utiliser cette nouvelle plateforme qu'on appelle « Jumeaux Numériques (JN) ou Digital Twin (DT) » pour améliorer leur travail. Un concept central de ce processus qui se présente sous la forme d'une plateforme logiciel représenté par une réplique virtuelle d'un jumeau réel qui est plus qu'un simple modèle numérique. Il peut s'agir d'une copie d'un produit, d'un processus ou d'un système informatique qui relie le monde physique réel au monde numérique virtuel par une circulation bidirectionnelle permanente de données multisources et multicateurs intelligents. Ce concept est né de la grande disponibilité des données et de l'augmentation de capacité à rassembler, organiser, manipuler, stocker et récupérer ces données. L'augmentation de la capture de données et la possibilité de construire des modèles prédictifs avec elles apportent des avantages considérables à la planification des infrastructures. Les données issues des capteurs intelligents

IoT permettent d'adapter la consommation d'énergie à l'approvisionnement ; les données des capteurs IoT optimisent les horaires des trains et l'efficacité énergétique ; les données climatiques et environnementales nous indiquent où construire des défenses contre les inondations et comment protéger un écosystème fragile.

Un JN est un puissant outil pour prendre en charge divers cas d'utilisation y compris dans le domaine de surveillance de l'environnement, la maintenance préventive des infrastructures, la planification de scénario, le climat, les énergies renouvelables, l'eau, les îlots de chaleur urbaine et la surveillance de l'état de santé des écosystèmes naturels. Dans le domaine particulier de la maintenance préventive. Cette technologie vise à éviter les défaillances inattendues du système (par exemple en raison de composants usés) en surveillant les tendances de certains indicateurs et en estimant le temps d'exécution restant jusqu'à la prochaine maintenance. Les indicateurs sont calculés au moyen d'un modèle de simulation représentant une copie du système réel - le fameux JN.

Un JN ou DT nécessite des données provenant de technologies tel que les SIG, images d'OT, données nuage de points 3D laser, BIM, IoT, ML afin de pouvoir comprendre l'état actuel d'un projet de suivi de santé d'une infrastructure routière. La combinaison des données des technologies d'ingénierie en un jumeau numérique permet des simulations, afin que les utilisateurs puissent essayer différents scénarios ou prédire les performances d'un modèle de contrôle ou de suivi. Un JN est le résultat d'une combinaison d'un modèle de calcul et un système du monde réel (infrastructures ou écosystèmes naturels), conçu pour surveiller, contrôler et optimiser sa fonctionnalité. Grâce aux données acquises par des satellites d'OT, des lasers ou par des objets connectés et le traitement de ces données par des algorithmes de ML, le JN peut simuler la réalité et prévoir des anomalies dans un système. Le JN peut développer des capacités d'autonomie et d'apprentissage sur son environnement (Grieves, 2014 ; Matthews, 2018 ; Marr, 2017).

Un JN consiste en une copie numérique d'une infrastructure, recensant toutes les informations sur l'état de santé de la structure de celle-ci. Les infrastructures routières sont essentielles pour soutenir la croissance économique et améliorer la qualité de vie grâce à des réseaux routiers

fonctionnels et sûrs. La transformation numérique des infrastructures est en marche, qu'il s'agisse d'un chantier, d'un immeuble intelligent, d'une usine, d'un service public ou d'une ville entière. Les organisations travaillant dans le secteur des infrastructures qui planifient, conçoivent, construisent et exploitent des infrastructures de tirer parti des JN pour améliorer leur flux de travail (Zeigler et al., 2018; Hammad et al., 2007; Shim et al., 2011).

Les JN ont été introduites pour la première fois en 2002 par Michael Grieves à l'Université du Michigan (Grieves, 2014). Ils nécessitent des données de technologies numériques opérationnelles telles que Internet des Objets ou Internet of Things (IoT), l'intégration GIS plus BIM avec l'apprentissage automatique afin de rendre les processus plus intéressants avec les données multisources et multicateurs et comprendre l'état actuel du projet ou de l'actif (fig. 56). La combinaison des données de la technologie d'ingénierie en un jumeau numérique permet des simulations, afin qu'on puisse essayer différents scénarios ou prédire les performances d'un actif (Matthews, 2018). Il contenait tout ce qui était familier avec le jumeau numérique, y compris ; espace réel, espace virtuel et diffusion des flux de données et d'informations entre espace réel et virtuel (Marr, 2017).




Figure 56. Le JN comme processus à l'intersection des technologies numériques les plus opérationnelles.

Notre objectif dans ce travail consiste à :

- Réaliser un modèle BIM du pont Mohammed VI à partir de données de nuages de points pour servir de plateforme virtuelle de son jumeau réel servant pour l'acquisition des données issues des capteurs IoT et pour toute communication bidirectionnelle entre les deux jumeaux ;
- Proposer un flux de travail basé sur la technologie JN pour le suivi, la maintenance et l'état de santé de cette infrastructure routière importante ;
- Proposer une automatisation de la surveillance et la maintenance de ce pont en utilisant les algorithmes ML/DL pour l'extraction des informations à partir des données collectées par les capteurs spatiaux, d'arpentage sur le terrain, de la disposition des composants, des matériaux, des coûts, des calendriers, des inspections et surveillances sur le terrain, de l'énergie, les émissions de carbone et par les appareils IoT.

5.2 Différence entre JN et BIM

Ce qui distingue un JN de tout autre modèle BIM est sa connexion à son jumeau physique. Alors qu'un modèle BIM capture la géométrie d'un objet avec ses attributs, un JN

incorpore également des données de capteurs connectés IoT. Un JN peut être utilisé pour montrer comment les composants discrets d'un système interagissent les uns avec les autres. Sur la base des données de du jumeau physique, un JN déverrouille de la valeur principalement en soutenant une prise de décision améliorée.

Un JN doit représenter la réalité physique à un niveau de précision adapté à son objectif. L'étendue du réalisme dépend de trois éléments essentiels :

1. Les données - la qualité des données sur lesquelles le jumeau est basé.
2. Le modèle - la fidélité des algorithmes, la validité des hypothèses et la compétence du code au cœur de la représentation numérique.
3. La visualisation - la qualité de présentation de la sortie.

Un JN peut être développé à différentes fins, fonctionner à différentes échelles ou adopter différentes approches de modélisation. Un certain nombre de JN ont déjà commencé à apparaître dans l'environnement bâti, à des fins diverses (Petty, 2017). Beaucoup d'autres seront créés. Cependant, peu de JN sont actuellement connectés ou partagent des données entre organisations, secteurs ou zones géographiques. Le manque d'interopérabilité est une contrainte clé.

Par exemple, dans le domaine des transports, pour faire progresser le JN tout au long du cycle de vie des infrastructures de transport couvrant la planification, la conception, l'analyse, l'entretien et l'exploitation des routes, des ponts et des tunnels peut être confronté à de nombreux défis. La nécessité d'augmenter l'efficacité, de minimiser la perte de données et de rationaliser les processus via un JN et un environnement de données connecté peut résoudre ces problèmes complexes et divers (Lee et al., 2015; Brettel et al., 2014; West et Pyster, 2015). Utilisez le concept JN d'infrastructure routière importante à l'échelle de la ville va permettre aux villes de créer, visualiser et analyser leurs données. Par exemple, collecter des données à des fins de planification de l'infrastructure routière et les mettre à la disposition des parties prenantes internes des différents services de l'organisation de la ville, ainsi qu'aux

citoyens (Volk et al., 2014 ; Shim et al., 2017 ; Shim et al., 2016). Pour les applications standard et faciles, la technologie JN offre de la valeur simplement en utilisant les sorties des capteurs connectés à l'infrastructure routière pour une visualisation simple des différents paramètres liés à la structure de l'objet en question et pouvoir suivre l'état de santé de cette infrastructure sans avoir à recourir au ML. Les exemples d'applications JN simples que l'on peut imaginer sont caractérisés par un nombre limité de paramètres et une relation linéaire facilement détectable entre les données d'entrée telles que les variables de la structure de l'infrastructure et les sorties des capteurs connectés. Cependant, la plupart des grandes infrastructures routières confrontées à de multiples flux de données devraient bénéficier de l'apprentissage automatique ou d'algorithmes d'apprentissage profond afin de les analyser et de donner un sens aux données.

5.3 Les caractéristiques et capacités clés d'un JN pour les ponts

- Il s'agit d'une réplique numérique du pont physique (processus et / ou système), en termes de géométrie et de nombreux autres aspects ;
- Les données sont l'ingrédient clé d'un JN pour les ponts, qui comprend des données d'arpentage sur le terrain, la disposition, les composants, le matériau, le coût, le calendrier, l'inspection, la surveillance, l'énergie, les émissions de carbone et des capteurs IoT installés sur le jumeau physique.
- Il est connecté au pont physique en ce sens qu'il peut être mis à jour et fournir une rétroaction dans le pont (par exemple, surveillance de l'état actuel) en temps quasi réel lorsque de nouvelles données sont collectées ;
- Il couvre tout le cycle de vie du pont physique, avec des données et des informations circulant à différentes étapes du projet de pont, ce qui comprend la planification, la conception, la construction, l'exploitation et l'entretien, la rénovation, la démolition, etc.

- Il a un environnement de données commun, avec toutes les données stockées dans un modèle et conditionnellement accessibles et modifiées par diverses parties prenantes du projet ;
- C'est un outil de visualisation qui peut être utilisé pour récupérer des données ou des informations dans leur contexte, faciliter la communication et la collaboration, etc. ;
- Il s'agit d'un outil de simulation (par exemple, basé sur la physique, basé sur les données ou les deux) qui peut être utilisé pour effectuer des scénarios de simulation afin d'évaluer les risques liés à l'état de l'infrastructure, de prédire la performance de celle-ci, etc. ;
- C'est un système auto-apprenant c'est-à-dire qu'il est capable d'apprendre de l'acquisition de nouvelles données de mesure pour améliorer les futurs projets et pratiques.

Une demande clé dans les processus de transformation numérique concerne les JN, c'est-à-dire les représentations numériques qui reflètent la forme, la structure, les relations et l'état des objets du monde réel (Schluse et al., 2017 ; Schluse et al., 2018 ; Ye et al., 2019). Les nuages de points 3D représentent des données brutes d'entités géospatiales d'une manière bien définie, cohérente et simple, en particulier pour les environnements thermiques tels que les espaces intérieurs modélisables à partir du nuage de point à l'aide du processus scan to BIM (Schluse et Rossman, 2016). La reconstruction de JN, sur la base de schémas de modèles 3D définis de manière explicite, est un processus non lourd et sujet aux erreurs (par exemple, les modèles BIM d'infrastructure détaillés tels que l'IFC LoD300 ou LOD400 ou ceux de ville 3D virtuels très détaillés tels que CityGML LOD3 ou LOD4). Comme les modèles 3D ont une gamme d'expressivité stricte, que nous appliquions des mathématiques fortes ou une heuristique affinée, un modèle 3D reconstruit manque presque toujours de détails et peut difficilement refléter des entités faiblement échantillonnées, inhabituelles ou floues (Guan et al., 2016). Les algorithmes de reconstruction des infrastructures routières à partir des nuages de points peuvent être regroupés en automatique et interactif en fonction du niveau requis

d'interaction de l'utilisateur. Les applications interactives sont principalement conçues pour gérer la rareté et les occlusions dans les données. Nous pouvons également classer diverses techniques de reconstruction des infrastructures routières en fonction des données d'entrée ou du modèle de sortie (Matthews, 2018 ; Marr, 2017 ; Ye et al., 2019). Par exemple, les algorithmes conçus pour fonctionner sur ALS (Airborne Laser Scanning) diffèrent considérablement de ceux développés pour MLS (Mobile Laser Scanning) et TLS (Terrestrial Laser Scanning) (Guan et al., 2016 ; Puente et al., 2013 ; Wang et al., 2018 ; Shim et al., 2019 ; NgocSon et al., 2018 ; Dang et Shim, 2018 ; Shim et al., 2011 ; Volk et al., 2014). Ce document traite d'une étude exploratoire visant à proposer un JN pour l'un des ponts les plus importants du pays. L'étude de cas a considéré le pont à haubans le plus long d'Afrique, le pont Mohammed VI au Maroc. L'étude propose un flux de travail pour le suivi, la surveillance et de maintien de l'état de santé de ce pont (fig. 57). Dans ce travail la cartographie mobile MLS a servi pour la construction du modèle BIM qui va représenter le socle de la plateforme JN. Le ML va servir pour développer une méthode de calcul efficace basée sur la fonction de distribution de probabilité décrivant les propriétés statistiques d'un ensemble de paramètres structurels liés à l'état de santé du pont (Farrar et Worden, 2013 ; Raimondo et al., 2017). La fatigue, la corrosion et les défaillances de connexion sont les principales préoccupations concernant l'état de santé de ce type de pont. Les systèmes de surveillance avancés ont besoin de modèles d'analyse pour évaluer en temps réel le comportement des ponts. Un modèle JN est considéré comme une plateforme pour intégrer ces nouvelles exigences pour une meilleure surveillance et maintenance du pont.

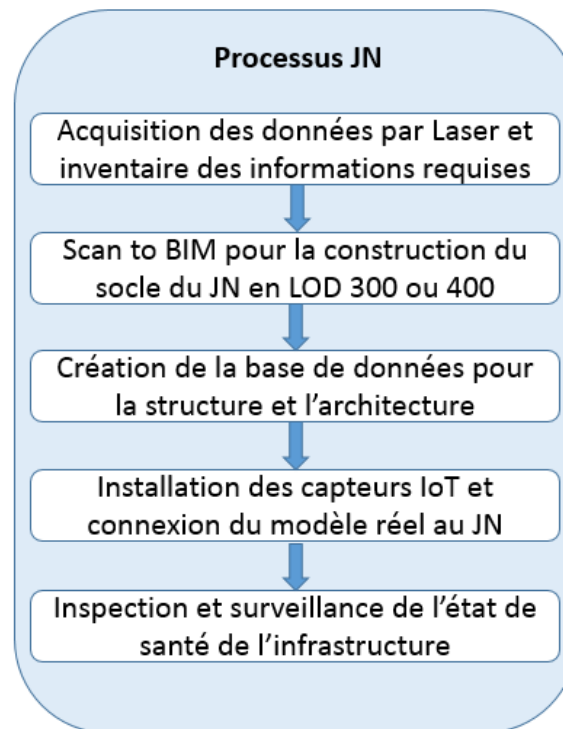


Figure 57. Flux de travail d'un JN pour une infrastructure routière.

5.4 Pont Mohammed VI

Ce pont à haubans traverse la vallée du Bouregreg et est une partie intégrante de cette route de contournement de Rabat. Ce projet, dont la construction a été lancée en février 2011, s'inscrit dans la politique des grands projets structurants au Maroc. Ce pont est soutenu avec 160 câbles en acier et se distingue par son architecture s'inspirant de la civilisation arabo musulmane dont les deux pylônes en béton élancés sous forme d'arche très aérodynamiques et qui symbolisent les nouvelles portes des deux villes Rabat et Salé. Reliant les principales autoroutes desservant le sud, le centre, le nord et l'est du pays, ce projet permettra de soulager le trafic sur le périphérique existant de la ville de Rabat, caractérisé par une forte concentration de trafic de marchandises lourdes, ce qui réduira considérablement les émissions de gaz à effet de serre. Le

projet comprend plusieurs aménagements : une jonction avec l'autoroute Casablanca-Rabat, un échangeur pour desservir la nouvelle ville de Tamesna, un échangeur au niveau de la ville de Menzeh donnant sur le boulevard Mohammed VI (Rabat), un échangeur à Sala Al Jadida et un autre au niveau de Technopolis. La nouvelle autoroute traverse l'oued Bouregreg par un pont à haubans (fig. 58). C'est le plus long pont à haubans d'Afrique, avec ses 950 mètres, ses deux tours de 200 mètres de haut et son tablier plus large que 30 mètres. Les deux grands pylônes sous la forme d'une arche symbolisent les nouvelles portes du deux villes Rabat et Salé. Le coût de tous les travaux de construction de la rocade de Rabat, dont le pont Mohammed VI, s'est élevé à 3,2 milliards de dirhams, financés par la Banque européenne d'investissement (BEI) et le capital de la Société nationale des Autoroutes du Maroc (ADM).




Figure 58. Localisation en (a) et une photographie (b) du pont du pont Mohammed VI

5.5 Matériel et méthodes

5.5.1 Le scanner laser mobile Leica Pegasus Two

Le Leica Pegasus Two est une solution de cartographie indépendante du véhicule combinant le LiDAR et des images panoramiques sans couture à haute résolution à 360° pour

les applications basées sur le SIG - droit de passage utilitaire, exploitation minière, construction, urbanisme et autorisations. Tirant parti de la plateforme de cartographie mobile de confiance de Leica Geosystem, le Pegasus : Two est la solution de numérisation d'entrée de gamme pour permettre votre entrée dans Mobile Reality Capture. Fournir une plateforme flexible d'application qui est légère, très efficace dans la capture de volume pour des décisions rapides et une facturation de projet. Avec un scanner laser ZF 9012 allant jusqu'à 1 million de points / s, sa précision horizontale est de 0,02 m RMS et sa précision verticale de 0,015 m RMS



Figure 59. Unité de Scanner Laser embarqué sur véhicule Leica Pegasus à Rabat

5.5.2 Acquisition et modélisation des ponts

Le flux de travail des produits Pegasus permet une capture rapide et efficace des fonctionnalités des scènes 3D et la numérisation des ressources. Pegasus Manager apporte une solution de workflow unique permettant l'extraction automatisée des fonctionnalités via plusieurs modules qui peuvent être ajoutés au besoin. Un module d'échange de données facilite également la localisation vers des progiciels tiers (Fig. 60).




Figure 60. De l'acquisition des données à l'interprétation des données pour l'inspection des ponts.

5.5.3 Post-traitement du nuage de point acquis par le scanner laser mobile Leica Pegasus Two

Après l'achèvement du travail sur le terrain, les données collectées sont traitées avec un logiciel compatible, intégrez toutes les données comme les coordonnées de localisation, les distances dans des formats numériques, les affichages virtuels de visuels réels. La sortie générée a abouti à un nuage de points géoréférencé combiné du pont. Et utilisé un logiciel spécifique pour l'analyse et l'inspection (Fig.61).




Figure 61. Nuage de points 3D du pont Mohammed VI obtenu à l'aide du système de cartographie mobile Pegasus Two de Leica Geosystems.

5.5.4 Modélisation BIM infra du pont Mohammed VI et intégration BIM SIG

5.5.4.1 Vectorisation : Scan 2 BIM par procédé semi-automatique

Bauer et al. (Bauer et al., 2003), Von Hansen et al. (Von Hansen et al., 2006) et Boulaassal et al. (Boulaassal et al., 2007) ont étudié l'utilisation de RANSAC (Random Sampling and Consensus consensus d'échantillonnage aléatoire), développé par Bolles et Fischler (1981), pour détecter des avions dans des nuages de points 3D. Son utilisation dans la détection et l'ajustement des cylindres a été testée par Chaperon et Goulette (Chaperon et Goulette, 2001) et la détection automatisée d'autres formes géométriques a été décrite dans Schnabel et al. (Schnabel et al., 2007 ; Nguyen et Le, 2013 ; Ni et al., 2017). Il s'agit d'un algorithme itératif dont le principe repose sur le calcul de la distance entre les points et une géométrie primitive choisie par l'utilisateur. Concrètement, à chaque itération, l'algorithme va sélectionner de manière aléatoire les points et créer la primitive géométrique correspondante. La distance entre cette dernière et les points du nuage va alors être mis à jour. Si cette distance est inférieure à

un certain seuil, le point est qualifié de point valable, aussi appelé inlier. Dans le cas contraire, le point est qualifié d'outlier. Au bout de N itérations, la primitive qui a obtenu le plus grand nombre d'inliers est retenue. Le choix du nombre d'itérations est primordial avec cette méthode. En effet, puisque les points initiaux sont choisis aléatoirement, plus la valeur itérative n'est importante, et plus la probabilité de détecter les meilleurs inliers augmente. La valeur de N est obtenue à la suite d'un calcul statistique visant à sélectionner aléatoirement les points valables parmi un nuage de n points (Bolles et Fischler, 1981). Ainsi, la valeur de N peut être mise à disposition tel que le montre l'équation 26:

$$N = \frac{\log(1-\rho)}{\log(1-(1-\varepsilon)^S)} \quad (26)$$

Où ρ représente la probabilité d'avoir au moins un échantillon composé uniquement d'inliers après N tirages et ε représente le pourcentage d'outliers dans les données.

L'explication et la preuve de cette formule est expliquée par Simonetto (Simonetto, 2018). Dans notre application nous utilisons les solutions de Leica Geosystems (Cyclone, Cloudworx) pour détecter les câbles et tuyauteries et générer les patchs (surfaces) de chaussée sur la base de l'algorithme RANSAC (fig. 62).




Figure 62. Détection des cablature en utilisant la solution Leica Geosystems (Cyclone, Cloudworx).

À partir du nuage de point, la structure du tablier du pont de la route a été modélisée à l'aide de Bridge Modeler sur Civil 3D et à l'aide de son plug-in Cloudworx Pro pour visualiser le nuage de points et dessiner selon la structure telle que construite (fig. 63c). Le jeu d'outils de Leica pour Revit est principalement axé sur l'amélioration de la façon dont nous pouvons afficher et interagir avec les nuages de points. Les plug-ins Leica CloudWorx nous permettent de travailler efficacement avec des données de nuages de points directement dans des applications de CAO et de réalité virtuelle (réalité virtuelle). Ils sont très populaires depuis leur introduction en 2001. Aujourd'hui, il existe huit plug-ins Leica CloudWorx différents pour des applications CAO et VR spécifiques. Leica CloudWorx pour Revit est le dernier ajout à la famille Leica CloudWorx. Il permet à l'utilisateur de gérer de très gros fichiers de nuages de points et de manipuler rapidement les numérisations - même les zones à haute densité - pour une visualisation 3D efficace. Nous avons également pu découper et recadrer rapidement les zones de nuages de points d'intérêt directement. De plus, la nouvelle version lui a permis d'effectuer des élévations et des plans de coupe rapides et précis, de définir des niveaux et des plans de travail, et de placer directement des objets d'intérêt, des luminaires et même de modéliser la tuyauterie, les câbles en acier et les deux pylônes en béton de 200 mètres de hauteur à partir de nuages de

points Ensuite, la texture a été rajouter pour que la modélisation des câbles et des deux pylônes soit la plus réaliste possible (fig. 63d).




Figure 63. Visualisation du modèle à l'aide du plugin Cloudworx; (b) et (d) Modélisation et reconnaissance des câbles en acier et deux pylône en béton à l'aide de Cloudworx Pro de Leica (c) Modélisation du tablier.

5.5.4.2 Flux de travail ETL (Extract -Transform-Load)


La majorité des conceptions de projets de construction sont exécutées avec des programmes de CAO (par exemple, AutoCAD et Revit) par des ingénieurs de planification et des architectes. Les planificateurs environnementaux et paysagistes, quant à eux, utilisent le SIG pour évaluer les impacts environnementaux des projets de construction et l'intégration visuelle, écologique et fonctionnelle du projet dans le paysage. Pour répondre à toutes les exigences, les jeux de données CAO des ingénieurs et des architectes devrait être convertis aux formats SIG et combinés avec les jeux de données SIG des planificateurs environnementaux et paysagers, afin que les analyses nécessaires puissent être effectuées.

En intégrant les processus de planification BIM dans une structure de géodatabase dans un système de planification collaborative, les informations correspondantes peuvent être échangées et traitées très rapidement. Cette approche peut être utilisée pour les bâtiments, les projets de génie civil, le développement urbain et, en particulier, pour la planification de grandes infrastructures. À cette fin, les modèles de données CAO et BIM 2D et 3D sont intégrés au modèle de données SIG - en totalité ou en partie - puis évalués. Le retour d'expérience de cette évaluation permet aux parties de déterminer l'impact potentiel des projets de construction sur l'environnement et les contraintes techniques ou infrastructurelles, et d'optimiser la conception et la construction d'ingénierie tout au long du cycle de vie du projet, en visant une solution durable et juridiquement acceptable.

5.5.4.3 Intégration du BIM infra dans un environnement de modèle SIG

La conversion bidirectionnelle entre les données BIM et SIG du Pont Mohammed 6 a été réalisée avec l'extension d'interopérabilité d'Esri, basée sur la méthode ETL (Extract-Transform-Load) utilisant la technologie logicielle FME, qui permet une comparaison et une évaluation faciles de la conception alternative CAO ou BIM et des scénarios de planification basés sur les bases de données SIG existantes (fig. 64 a et b).

La figure 86 montre schématiquement comment la structure des couches de données de base SIG, de données environnementales et de données BIM a été combinée (de bas en haut) dans une géodatabase 2D / 3D pour le Pont Mohammed 6. La technologie SIG appliquée permet la combinaison de chaque couche de cet ensemble de données et l'évaluation de tout impact entre les couches de données 2D ou 3D pertinentes.



(a)

(b)

Figure 64. Flux de travail pour l'intégration du BIM et du SIG en utilisant l'Extension Esri Data Interoperability sur FME




Figure 65. Exemple de migration de données BIM vers SIG pour une structure de pont.

Le BIM sert d'intermédiaire d'interopérabilité entre les acteurs de l'industrie de construction, renforçant ainsi sa popularité auprès des clients (fig.65) (Xie et al., 2017 ; Costin et al., 2018 ; Farrar et Worden, 2013 ; Kang et Hong, 2015). D'autre part le modèle de ville 3D visualise et analyse les problèmes liés à la localisation dans les sciences géospatiales et la gestion des ressources naturelles en intégrant différentes données spatiales et d'attributs et en tirant des connaissances grâce à divers outils d'analyse spatiale 3D et modes de modélisation (Yamamura

et al., 2017 ; Nikoohemat et al., 2017 ; Costin, 2016 ; Biljecki et al., 2015 ; Zlatanova et al., 2002 ; Kang et Hong, 2015 ; Mignard et Nicolle, 2014).

5.6 Inspection du modèle

5.6.1 Analyse du pont au sein de son environnement spatiale

Une fois préparé, l'ensemble de données BIM et SIG intégré peuvent être utilisé pour deux analyses environnementales, simulation de trafics et d'intensité des vents. Une validation et une analyse de la végétation peuvent également être effectuées entre l'état avant et après construction pour identifier les sites potentiellement problématiques causés par la flore et la faune protégées (par exemple, les zones de reproduction et les périodes). Pour cette analyse, des géométries BIM / SIG ont été utilisées en combinaison avec des données SIG. Les résultats ont été écrits dans les tables d'attributs des géométries, prêts à être exportés et remis aux planificateurs d'infrastructure après l'analyse. La modélisation du pont Mohammed VI a également été intégrée dans un environnement de simulation et vue dans un environnement de modèle de ville 3D (fig. 66).




Figure 66. La modélisation du pont Mohammed VI a été intégrée dans un modèle de simulation 3D CIM.

5.6.2 Auscultation Volumétrique

Les éléments en béton sont largement utilisés dans la construction de bâtiments et d'infrastructures civiles car ils offrent une meilleure qualité de construction et nécessitent moins de temps de construction. Cependant, des anomalies dans les surfaces en béton telles que la non-planéité ou la distorsion sont apparues sur le pont, et elles influencent la stabilité des éléments ainsi que les performances fonctionnelles des connexions entre les éléments (câbles de maintien). Cependant, les méthodes traditionnelles de SFDI qui sont effectuées manuellement ou par des dispositifs de type un contrôle à vue d'œil sont, cependant, longues, laborieuses et sujettes aux erreurs. Ainsi, il est important d'entreprendre une inspection de planéité et de déformation des surfaces (SFDI) sur la chaussée de façon continue tout au long du cycle de vie de l'ouvrage. Nous avons utilisé le logiciel Cyclone 3DR et son module d'arpentage pour faire le calcul et l'estimation de surface directement sur le nuage de points pour l'exploitation massive des données que nous avons choisi d'importer le nuage de points en tant que base de données Cyclone.

La commande Planéité de surface permet de vérifier s'il y a des bosses de trous dans une surface plane sur la base d'un plan conceptuel. Nous avons appliqué les paramètres suivants pour vérifier la planéité : définir 1 m pour la dimension de la règle et 0,005 m pour la tolérance. Cela

signifie que si nous plaçons une règle de 1 mètre de long sur le sol, nous n'aurons aucune mesure de point du sol à plus de 5 mm de la règle.

5.6.3 Inspection d'alignement, de distorsion et de planéité du tablier du pont

Au tout début de tout projet de maintenance d'infrastructure, les modèles 3D doivent être rapidement inspectés, afin que les proportions et la forme soient mieux appréciées. À cet égard, l'alignement du pont est le principal facteur dans le processus de conception ainsi que le contrôle géométrique ultérieur. L'alignement des ponts donne non seulement une idée plus précise de l'apparence du modèle final, mais crée également une prémisse pour le modèle d'analyse à des fins d'évaluation (Olsen et al., 2011). En utilisant une approche de modélisation paramétrique basée sur l'alignement, l'ensemble du modèle de pont peut être généré par une combinaison d'alignement horizontal / vertical et de certaines définitions du profil de section. Sur la base des différentes tâches du processus de conception, une chaîne d'alignement de pont est identifiée. Par exemple, un désalignement dans un pont suspendu par des câbles peut provenir d'un ancrage peu fiable et d'une déformation instable du panier suspendu résultant de la différence entre la structure du panier suspendu et les exigences de construction en sont la cause principale. Les éléments en béton sont largement utilisés dans la construction de bâtiments et d'infrastructures civiles car ils offrent une meilleure qualité de construction et nécessitent moins de temps de construction. Cependant, des anomalies dans les surfaces en béton telles que la non-planéité ou la distorsion sont apparues sur le pont, et elles influencent l'érection des éléments ainsi que les performances fonctionnelles des connexions entre les éléments. Cependant, les méthodes traditionnelles de SFDI qui sont effectuées manuellement ou par des dispositifs de type contact sont, cependant, longues, laborieuses et sujettes aux erreurs. Ainsi, il est important d'entreprendre une inspection de planéité et de déformation des surfaces (SFDI) sur les éléments en béton préfabriqué avant leur livraison sur les chantiers de construction. Nous avons utilisé le logiciel Cyclone 3DR et son module d'arpentage pour faire

le calcul et l'estimation de surface directement sur le nuage de points pour l'exploitation massive des données que nous avons choisi d'importer le nuage de points en tant que base de données Cyclone (Fig.67).




Figure 67. Inspection d'alignement, de distorsion et de planéité sur un seul tablier du pont.

5.7 Proposition du JN pour le pont

5.7.1 Le JN comme solution proposée pour la surveillance continue de la structure du pont à l'aide de capteurs IoT placés sur le jumeau physique

Il est bien connu que l'inspection visuelle est hautement subjective. Les résultats de ces inspections visuelles peuvent être très variables et dépendent de nombreux facteurs qui provoquent des erreurs. De plus, les relevés instrumentaux traditionnels sont soumis à l'expérience des ingénieurs civils, l'analyse traditionnelle à un effet particulier, elle est limitée à une petite quantité de mesure sur le terrain dans un temps limité et dans un espace limité. Avec les JN, nous pouvons avoir une inspection continue du pont à la fois dans le temps et dans l'espace en plaçant un grand nombre de capteurs de divers paramètres tels que : les accéléromètres ‘‘2D’’ permettant la mesure de l'accélération du pont sur 2 axes, l'enregistrement des vibrations et la mesure de la fréquence propre du tablier ; les anémomètres ‘‘3D’’ permettant la mesure de la vitesse du vent sur 3 directions et la mesure de la température de l'air ; les sondes de températures à béton permettant la mesure de la variation quotidienne de la température par rapport à l'air. Aussi des capteurs pour mesurer l'inclinaison, la corrosion dans toute la structure du pont (Fig. 68).




Figure 68. Exemple de notre architecture de capteurs IoT proposée dans le JN du pont Mohammed VI.

5.7.2 Flux de travail pour le JN proposé pour la surveillance et la maintenance de pont Mohammed VI en utilisant les algorithmes ML/DL.

La détection des dommages peut être résolue à l'aide de techniques d'apprentissage automatique et d'apprentissage en profondeur. Dans le suivi de l'état de santé structurelle, de nombreux facteurs influencent la réponse structurelle, entraînant une incertitude dans la valeur exacte à attribuer aux modèles susmentionnés. Pour cette raison, il est raisonnable de considérer les modèles comme des variables aléatoires et de résoudre le problème de la surveillance de la santé structurelle des ponts dans le contexte de l'application d'algorithmes d'apprentissage automatique. Ainsi, le modèle que nous proposons inclut l'application de ces algorithmes sur les données très massives provenant des capteurs IoT (fig.69).




Figure 69. Flux de travail pour le JN proposé pour surveiller et entretenir le pont Mohammed VI.

5.8 Conclusion

Dans ce chapitre, nous avons proposé un exemple de flux de travail pour le développement d'une plateforme JN dédiée à la surveillance et à la maintenance du pont Mohammed VI. Ce flux de travail à débiter par la création d'un modèle BIM infra du pont à partir de données de nuages de points capturées par un laser MLS pour servir de plateforme du model numérique pour ce JN. Sur le jumeau physique c'est-à-dire le pont nous avons proposé d'installer un certain nombre de capteurs IoT pour l'acquisition des informations sur l'état de la structure de ce pont et pouvoir suivre les paramètres physiques dans le temps et dans l'espace et fournir une auscultation volumétrique basée sur la structure de ce pont. La phase de création du model BIM a nécessité une automatisation de l'extraction à partir du nuage de point des objets BIM de l'infrastructure en utilisant des algorithmes de ML dans un procédé de scan au BIM. Ce model a un rôle très important car il représente la plateforme qui va recevoir le flux de données depuis

les objets connectés à chaque constituant du pont que nous voulons surveiller pendant tout le cycle de vie du pont.

Les tâches de maintenance peuvent être considérablement améliorées par le modèle proposé qui peut rendre cette surveillance et cette maintenance plus intelligentes et continues dans le temps, dans l'espace et de manière automatique et pouvoir analyser ces données grâce à des algorithmes ML/DL.

Les jumeaux numériques ont le potentiel d'aider à relever bon nombre des principaux défis auxquels nous sommes confrontés aujourd'hui, y compris dans le contrôle et la surveillance des infrastructures routières.

Chapitre 6 : Discussion générale

6.1 Introduction

La détection des changements est l'une des principales applications des données d'OT (Campbell and Wynne, 2011). Avec le développement de la technologie et des données d'OT, la détection de changement a connu une évolution substantielle des analyses spectrales et statistiques traditionnelles basées sur les pixels vers des techniques avancées et pionnières, qui sont basées sur l'utilisation des algorithmes d'IA et qui sont toujours en cours de développement. Pour réussir ce grand défi de détection des changements, il faut faire collaborer les deux approches spectrale et catégorique.

Le traitement catégorique des données générées à partir des capteurs optiques et radar vise à produire une cartographie précise de la surface de la terre qui sera utile pour diverses applications. Ce traitement implique l'utilisation d'algorithmes et de stratégies de classification qui vont d'un simple modèle mathématique ou statistique à des techniques plus avancées basées sur l'intelligence artificielle. Le choix des techniques utilisées dépend du niveau d'information requis et la qualité supérieure des données peut normalement fournir un niveau élevé d'information nécessitant une approche plus sophistiquée du traitement des données. Il existe un lien évident entre les développements technologiques en matière d'OT qui font appel à des algorithmes de traitement plus avancés nécessitant par fois des approches collaboratives combinant des données multisources et multicapteurs (Hakdaoui et al., 2019; Hakdaoui et Emran, 2020; Hakdaoui et al., 2020; Troya-Galvis et al., 2016). Avec les avancées technologiques en matière d'OT, des capteurs plus avancés sont disponibles, tels que les capteurs hyperspectraux, les lasers d'imagerie et les capteurs multispectraux à haute résolution, capables de produire des données à très haute résolution. Ces données à haute résolution requièrent des méthodes avancées de traitement des signaux et des images, telles que celles issues des domaines de l'intelligence artificielle et de l'apprentissage automatique. Grâce à la

combinaison de capteurs avancés et la collaboration d'algorithmes de traitement plus intelligents, de nouvelles applications dans différents domaines peuvent être réalisées.

Jusqu'à présent, les techniques d'apprentissage automatique (Machine Learning ML) se répandaient au fur et à mesure que les logiciels disponibles avec ces approches se généralisaient. Cependant, il est également important de noter que plus le niveau d'information à extraire augmente et se complique, plus il est nécessaire de savoir utiliser et combiner diverses méthodes d'extraction d'information : spectrales et catégoriques basées sur les algorithmes d'apprentissage automatique. Dans ce travail, nous avons combiné ces deux approches dans deux applications très variées.

Alors que les premières approches de classification ont été conçues il y a plus de quarante ans avec l'apparition des premiers satellites (Kettig et al., 1976), les récents développements technologiques posent de nouveaux défis. Le premier défi consiste à adapter les méthodes de classification aux caractéristiques des nouveaux capteurs, car les méthodes les plus récentes peuvent ne pas être directement applicables ou ne pas donner des performances satisfaisantes. Par exemple, les premiers capteurs satellitaires ont capturé des données à faible résolution spatiale et des recherches importantes ont été consacrées à la découverte des proportions (ou des abondances) de matériaux physiques dans chaque pixel (Keshava, 2003). Les capteurs récemment développés acquièrent des images à haute résolution spatiale, où les pixels deviennent petits par rapport aux objets. Cela implique la nécessité d'une analyse basée sur les objets, en d'autres termes le développement d'algorithmes qui apprennent à analyser la cohérence et la relation entre des groupes de pixels de l'image, dans le but d'identifier les objets entiers.

Le deuxième défi est l'évolutivité des systèmes. Avec l'augmentation de la quantité et l'ouverture croissantes des données couvrant une large étendue géographique, il existe un intérêt croissant pour le développement de méthodes évolutives capables de produire des cartes de classification multitudes sur de vastes zones, à l'échelle des villes, des pays, des continents et de la Terre entière (Mattyus et al., 2015). Cet objectif ne peut être concrétiser que si on

adopte une approche de traitement distribué basée sur l'utilisation de plateformes Big Data telle que celle présente sur la plateforme GEE.

6.2 Pourquoi le choix des provinces Sud du Maroc

La plupart des zones désertiques ne sont pas géologiquement équipées pour que l'eau s'infilte dans le sol. Par conséquent, s'il y a une quantité anormale de précipitations en très peu de temps, elles se rassemblent en ruisseaux et rivières d'eau qui coule rapidement en inondant ces zones. En règle générale, ces zones sont très rocheuses et ont peu de sol pour absorber l'eau, par conséquent, le résultat est le ruissellement. Un écoulement de volume suffisant devient une crue éclair. L'étude de la réponse des rivières et des zones humides aux crues éclair dans un environnement désertique est un travail de recherche très rare dans la littérature. Dans notre cas d'étude, nous nous sommes concentrés sur deux régions :

- La ville de Laayoune avec son barrage de Sakia El Hamra et ses deux Sebkhas pour étudier leurs réponses à une crue éclair.
- La Sebkha d'Imlili qui est classée comme écosystème Ramsar, pour faire un suivi de son état et étudier sa réponse à ces changements climatiques.

L'intérêt de cette démarche est de faire un suivi des changements sous l'influence des changements climatiques sur cette région du Sud du Maroc lors d'évènements :

- Inondations éclaires (cas de la ville de Laayoune)
- Influence d'une période de sécheresse sur un écosystème fragile (cas de l'étude sur la Sebkha d'Imlili)

Dans la détection des changements à partir des images spatiales, le grand défi est de séparer les vrais changements thématiques de ceux qui sont seulement spectrales. Pour cela il faut choisir des images qui sont :

- Captées à un moment similaire de la journée (même éclairage). Cette condition est souvent réalisée dans le cas des milieux désertiques.
- Captées au cours de la même saison (afin d'éviter les changements de végétation). Il faut faire attention aux différentes quantités de précipitations annuelles et tenir compte des années de sécheresse et des années sans sécheresse. Cette condition est toujours vraie étant donné la rareté de la végétation et des précipitations dans les milieux désertiques.
- Captées avec absence de couverture nuageuse. Condition souvent réalisée dans les milieux désertiques.

Nous avons orienté notre choix sur le radar en milieu désertique car contrairement à la télédétection optique, la rétrodiffusion radar est sensible à un ensemble différent de propriétés telles que la rugosité de surface, la pente, la propriété diélectrique du matériau de surface et l'humidité des sols. L'image radar a ses propres caractéristiques. L'effet d'ombre, par exemple, est utile pour l'analyse de terrain. Les différences d'élévation subtiles, qui ne sont pas directement perçues dans l'image de télédétection optique, sont mises en évidence dans l'image radar. De tels changements subtils du relief peuvent avoir une signification en néotectonique ou représenter une condition aux limites des formations géologiques.

L'interprétation de l'image radar est basée sur la forme, la texture et le motif topographiques, la position topographique, la présentation pseudo-3D de la forme (pente) et le contexte géomorphologique régional. Aussi, l'onde radar interagit différemment selon l'humidité dans les cas suivants :

- Sol inondé : la réflexion est spéculaire, ce qui nous donne une très faible rétrodiffusion. Les zones inondables sur le SAR apparaissent en noir (Fig. 70a).
- Sol humide : une grande différence dans les propriétés diélectriques entre l'eau et l'air cause une augmentation de la rétrodiffusion (Fig. 70b)
- Sol sec : cas généralement rencontré dans les zones très arides une partie de l'énergie incidente radar est capable de pénétrer dans le sous-sol causant une diminution de la

rétrodiffusion et donc dans ce cas, le radar pénètre le sol et nous permet d'extraire de l'information du sous-sol (Fig. 70c)




Figure 70 (a) Interaction de l'onde Radar SAR avec un sol inondé, (b) sol humide et (c) sol sec

Aussi, le radar possède un coefficient de rétrodiffusion radar σ^0 (quantité d'énergie qui revient vers le radar) qui dépend de :

- La rugosité de surface
- La permittivité diélectrique du milieu (liée à la teneur en eau)

Le coefficient de rétrodiffusion radar σ^0 augmente dans deux cas quand la rugosité du terrain est élevée et quand le taux d'humidité des sols est élevé, ce scénario crée une confusion lors des interprétations dans les zones à climat tempéré (Fig. 71). Dans les zones arides du sud du Maroc, la rugosité des surfaces est faible ainsi une augmentation de la rétrodiffusion ne peut être expliquée que par une augmentation de l'humidité du sol.



Figure 71 Indétermination entre le comportement d'un sol sec et rugueux avec un sol humide et lisse.

Le fait que le radar soit particulièrement sensible au relief nous donne des images avec beaucoup d'artefacts géométriques liés à la vision en distance de ce capteur. Or les zones

d'étude que nous avons choisie sont dépourvues de relief et par conséquent ces déformations sont très faibles voire inexistantes dans ces régions.

6.3 L'apport des algorithmes d'IA et de la méthodologie collaborative proposée

L'algorithme de classification Support Vector Machine (SVM) à noyau RBF est supervisé et non paramétrique et ne nécessite aucune hypothèse sur la distribution de données sous-jacente. Ce noyau RBF nous a donné le meilleur résultat comparé avec d'autres noyaux que nous avons testé. Ce résultat est en accord avec ceux que nous avons trouvés dans la littérature. Le SVM est fondée sur la théorie de l'apprentissage minimisant les risques structurels pour la classification. Lorsqu'il est appliqué sur des images multi-temporelles et appliqué de manière collaborative avec d'autres techniques de détection des changements comme l'analyse par vecteur de changement (CVA). Cette technique de détection de changement hybride se réfère à l'utilisation de deux approches (spectrale et catégorique) donne des résultats très satisfaisants.

Les zones humides arides sont importantes pour la conservation de la biodiversité, mais elles sont également très sensibles et vulnérables à la variabilité climatique et aux événements hydroclimatiques extrêmes (Touzi et al., 2005; Hostache et al., 2012; Xiua et al., 2019; Guo et al., 2014). L'amplification du cycle de l'eau, ainsi que la fréquence et la gravité croissantes des épisodes de sécheresse et d'humidité extrêmes, devraient modifier les modèles hydrologiques spatio-temporels des zones humides, avec des menaces potentielles pour les fonctions des services écosystémiques (Toyra et Pietroniro, 2005; Hostache et al., 2012). Ici, en utilisant des données spatiales multicapteurs et multitemporelles, nous avons étudié la réponse à l'événement de crue éclair de deux zones humides désertiques : la rivière et les systèmes Sebkh. Nos observations peuvent être résumées comme suit :

Dans les zones humides inondées, les eaux libres et la végétation inondée absorbent généralement le rayonnement proche infrarouge et sont représentées par de faibles valeurs DN

dans les images optiques, tandis que les zones non inondées génèrent des valeurs DN plus élevées en raison de l'émission de rayonnement infrarouge (Schmid et al., 2005; Hostache et al., 2012). Lors des inondations dans les milieux humides désertiques et les zones à faible couvert végétal, les sédiments mélangés à l'eau sont très abondants. Ces matériaux ont une réflectance plus élevée que l'eau claire et peuvent entraîner des erreurs de classification. Pour extraire l'étendue de l'eau et compenser ces déficiences, nous nous sommes intéressés aux changements de valeur de pixel provoqués par cet événement, au lieu de nous concentrer sur la valeur du pixel lui-même. Ainsi, nous avons déterminé des informations sur l'étendue de la crue éclair en utilisant les changements de surface temporels et spatiaux dans les zones inondées en utilisant des indices spectraux humides et secs du sol et de l'eau.

Les limites des résultats présentés sont la faible disponibilité des images optiques conformément à une forte probabilité de couverture nuageuse pendant la période d'inondation éclair. Cela représente une contrainte lors de l'utilisation de capteurs optiques plutôt que de capteurs SAR pour cartographier et surveiller les inondations des rivières et des zones humides. Cependant, notre étude fait exception à cette règle, car la disponibilité de données optiques sans nuage était temporellement plus proche de l'événement que les données SAR. Cela peut être une conséquence de la nature très brève de cet événement, de la rareté des nuages dans ces zones désertiques ainsi que de la bonne résolution temporelle du capteur Sentinel-2.

L'approche collaborative combine les avantages des deux processus: le traitement catégoriel fournit les bords précis des classes de changements majeurs et ne peut pas faire la distinction entre les types de changements secs / humides; avec le traitement spectral, les valeurs de pixels dans les bandes originales sont traitées comme des vecteurs de données de différence transformées en plus du vecteur de changement (CV), qui est calculé en soustrayant des vecteurs pour tous les pixels à des dates différentes. La direction du CV représente le type de changement, tandis que l'amplitude du changement correspond à la longueur du CV (Chen et al., 2003). Ainsi, l'espace des caractéristiques (Δ (Albedo), Δ (NDMI)) dérivant de l'imagerie de télédétection optique multi-temporelle permet de déterminer le changement radiométrique, tandis que le traitement catégorique permet de déterminer le changement thématique.

La sensibilité des images SAR aux variations d'humidité de surface peut faciliter les analyses géologiques et géomorphologiques (Emran, 2016). L'utilisation d'un flux de travail basé sur le Big Data géospatiale et les traitements de classification par l'algorithme RF (Random Forest) en mode distribués que nous avons développé sur la GEE et qui nous ont permis de cartographier, de surveiller et de suivre efficacement et rapidement les cavités d'eau salée de la Sebkhah d'Imlili. La RF a été choisie en raison de ses multiples avantages. Il ne fait aucune hypothèse sur la distribution normale des données d'entrée. Il peut donc accueillir les différences de distribution des données entre le SAR polarimétrique et des données optiques (gaussiennes). De plus, plusieurs d'autres études ont montré que la RF améliore la classification par rapport au classificateur de maximum de vraisemblance (MLC). La RF est également capable d'accueillir plusieurs types de bandes d'entrée (données de réflectance, rétrodiffusion, etc.). C'est donc un idéal classificateur pour combiner l'imagerie SAR multi-polarisation avec l'imagerie optique multi-temporelle et multi-indicielle. La RF n'est pas non plus sensible au bruit. Enfin, RF peut classer l'importance de chaque variable intervenant dans la classification afin que les variables les plus influentes dans la classification puissent être identifiées.

Les infrastructures routières et les ponts au Maroc doivent être maintenus en service au-delà de leur durée de vie. Ces infrastructures sont évaluées sur la base des résultats d'inspections visuelles et manuelles :

- Souvent très subjectives ;
- Ne peuvent pas identifier la détérioration interne ou les défauts ;
- Ne fournissent pas de données quantitatives à utiliser dans une évaluation ;
- Ils sont à haut risques pour les personnes responsables de la maintenance ;

L'avantage du balayage laser Scanner Mobile (MLS) par rapport aux méthodes d'arpentage conventionnelles résulte dans l'efficacité de l'acquisition des données spatiales. Le MLS fonctionne par onde lidar et détermine sans contact les coordonnées spatiales des points se trouvant à la surface de l'objet mesuré à des précisions millimétriques. Il permet une réduction significative du temps de mesure et de meilleurs résultats.

6.4 Conclusion

Les zones humides du désert ont tendance à être des écosystèmes fragiles, dans lesquels peu de perturbations peuvent y provoquer d'énormes changements dans leur paysage. Ce sont des milieux d'une importante richesse. Ces zones humides fournissent l'eau et les aliments à d'innombrables espèces de plantes et d'animaux vivant dans le désert. Les images radar utilisées dans ce travail nous ont permis de comprendre le mode de fonctionnement hydrologique de la Sebkha d'Imlili par la découverte d'un réseau hydrologique souterrain sur les images issues de la fusion de l'image optique multispectrales et l'image radar SAR polarimétrique. Ces images sont non seulement bien adaptées à l'étude des zones désertiques mais permettent également un meilleur suivi des zones inondables du désert.

Partie 2 : Conclusion

L'arrivée simultanée et la disponibilité croissante des technologies et des services de Cloud Computing ajoutent de la valeur aux grands volumes de flux de données satellitaires en libre accès. En effet, effectuer une analyse chronologique des images satellites en utilisant des ressources informatiques locales est difficile notamment sur une zone donnée, comme celle que nous présentons dans notre étude. Avec l'émergence des Big Data géospatiales, des réseaux et des services gratuits tels que GEE, nous avons juste besoin d'une connexion Internet fiable pour y accéder, contrôler et analyser d'énormes quantités de données. L'utilisation croissante d'algorithmes d'apprentissage automatique, tels que la SVM et RF, permettent également une cartographie précise et rapide des écosystèmes naturels en raison de leur grande adaptabilité aux données radar et optiques relativement complexes et volumineuses. Parallèlement, les approches scientifiques standard de l'analyse d'images d'OT ont tendance à concentrer sur des modèles de données simples, telles que la classification paramétrique basée sur des hypothèses sur une distribution gaussienne des densités de probabilité des valeurs de l'image. Ainsi elles ont une capacité limitée à gérer des ensembles de données complexes, tels que les Big data géospatiales.

Conclusion Générale et Perspectives

La première application des données d'OT a été la surveillance de l'étendue de l'eau dans une zone humide après des crues éclair dans la région saharienne du Maroc. À l'aide de données spatiales multicapteurs, nous avons montré les changements de l'étendue spatiale de l'eau dans cette zone après un événement d'inondation éclair (flash flood) causé par des pluies diluviennes et la crue de l'Oued Sakia-Al Hamra. Cette étude a utilisé des données optiques, des données SAR radar et des approches collaboratives combinant un traitement spectral et catégorique. Dans cette application, nous avons vu l'importance des algorithmes de ML pour l'extraction d'information à partir d'images d'OT. Ce travail a montré que le retour à la situation normale de l'eau dans le barrage après une inondation dans un environnement aride a pris environ deux mois. De plus, cette étude a suivi l'état d'humidité de surface à la suite de cette crue éclair dans cette région déserte, dans le but de présenter les causes sous-jacentes et permettre une bonne gestion des risques. Parmi les perspectives visées dans ce travail nous comptons; la mise en pratique du flux de travail que nous avons proposé pour le développement d'un JN de résilience aux inondations. En effet, si un tel JN existe pour cette zone, intégrant des données mesurées en temps réel par des capteurs IoT placés dans des endroits bien choisis. Ainsi, il serait possible d'alimenter le modèle virtuel pour analyser les impacts d'un tel événement météorologique et donc élaborer un plan d'action correctif. La capacité à réagir rapidement et à se remettre des événements inattendus dans une ville est essentielle pour accroître la résilience. D'où l'intérêt de créer un JN de résilience aux inondations utilisant des algorithmes de ML pour simuler et évaluer divers scénarios d'inondation et développer une stratégie d'atténuation avec des informations précises provenant de ce JN.

Dans la deuxième application de ce travail de recherche, nous avons vu que la combinaison des données issues des Big Data géospatiale, des traitements par algorithmes ML en mode distribué, qui offre de nombreuses possibilités d'applications géospatiales pour le suivi des changements temporels et spatiales des écosystèmes fragiles. Notre étude s'est concentrée sur

la cartographie, la surveillance et le suivi des conditions des états humide / sec de surface autour des cavités d'eau permanentes. Cet écosystème saharien de zones humides est très vulnérable. Les résultats que nous avons trouvés, mettent en évidence les fonctions des cavités d'eau salée dans la Sebkha d'Imlili et les valeurs écologiques de cette zone. Le flux de travail que nous avons proposé est basé sur la collaboration de plusieurs types de données Radar, optique. D'autre part, les prétraitements, l'analyse spectrale et la classification par l'algorithme RF dans un environnement distribué de la plateforme GEE, nous a permis de cartographier, de surveiller et de suivre les cavités d'eau salée de la Sebkha d'Imlili efficacement, rapidement et sans avoir à télécharger les données. Les résultats montrent non seulement les plus-values apportées par la surveillance et le suivi à long terme pour la protection efficace et durable de cet écosystème fragile, mais nous aident, également, à comprendre la fonction de ces zones humides sahariennes. En perspective pour ce travail de recherche, nous souhaitons étendre ces travaux à toutes les Sebkhas des régions Sud du Maroc à l'aide de la plateforme GEE qui est bien adapté à un contexte régional. Ensuite, utiliser le Radar Full Polarimétrique RADARSAT-2 (Quad-Pol) pour évaluer l'utilisation des fonctionnalités RADARSAT-2 Full Polarimétrique et multifaisceaux pour la cartographie géologique, géomorphologique et tester de nouveaux paramètres polarimétriques et de nouveaux outils de décomposition polarimétrique dans un contexte désertique. Enfin, et en liaison avec la technologie JN, il serait possible de développer un JN pour la protection de cet écosystème rare et fragile permettant la surveillance, l'analyse et la simulation des changements qui peuvent l'affecter. Le point de départ pour développer ce JN, est la numérisation des différentes caractéristiques environnementales, de biodiversité et écologiques de ce système pour servir model numérique du JN. Ensuite, il faut intégrer tous ces données SIG numérisées, les données spatiales et les données des capteurs IoT. Enfin, il faut établir les communications bidirectionnelles entre les deux jumeaux numérique et physique. Ainsi, ce travail montre bien que les données d'OT constituent un grand support pour beaucoup d'applications environnementales et écologiques. Ceci est possible pour comprendre la hiérarchie de flux de données spatiales pour développer des plateformes JN. Ce flux de données que nous avons proposé et qui montre comment il est possible d'exploiter toute la

richesse, la diversité et le volume de ce Big Data géospatial en les intégrant dans ces plateformes JN. Si en outre, les flux de données entre le jumeau physique existant et le système numérique virtuel (JN) sont entièrement intégrés dans les deux sens, nous pourrions agir et anticiper sur tout incident ou anomalie du jumeau physique. Un changement d'état du jumeau physique entraîne directement un changement d'état du JN et inversement.

Dans la dernière application de ce travail de recherche, nous avons proposé un flux de travail complet pour le développement d'un JN dédié à la surveillance, l'analyse et à la maintenance du pont à haubans de Mohammed VI. Une mise en pratique de ce flux de travail et des considérations essentielles pour la surveillance et la maintenance de ce pont important ont été réalisées. La création de modèles BIM infra (ou Civil Information Model) du pont à partir de données de nuages de points acquis par MLS a été réalisée pour servir de modèle numérique du JN. Ce dernier, communiquera avec son jumeau physique par le biais capteurs IoT bien placés sur celui-ci. Les données de ces capteurs seront traitées par des algorithmes ML bien installés dans la plateforme logiciel JN afin de pouvoir suivre dans le temps et dans l'espace l'état de santé du pont et fournir une auscultation volumétrique basée sur la structure du pont. Sur la base de ce flux de travail suggéré et des informations nécessaires de levé du pont, des tâches de maintenance peuvent être considérablement améliorées par le modèle proposé, qui peut rendre cette surveillance et cette maintenance plus intelligente, automatique et continues dans le temps, dans l'espace.

Tout ce travail de recherche montre que la convergence des technologies JN, la 3D, le BIM, le SIG, l'IoT, le Big Data géospatial et l'utilisation des algorithmes de ML/DL pour les traitements de ces données dans un environnement distribué vont automatiser et améliorer d'avantage les flux de travaux numériques et changer la façon actuelle de notre mode de travail. Il ne fait aucun doute qu'il y a eu une croissance continue de l'infrastructure numérique et de l'écosystème des technologies numériques avec ces technologies en évolution continue. Cette émergence accélère encore la portée et la contribution mondiale du géospatial. Dans les temps à venir, et avec l'arrivée en puissance du très haut débit de la 5G, nous allons voir une accélération de cette convergence des technologies des JN, du géospatial, l'IoT avec l'IA et

ses sous-ensembles, à savoir les machines d'apprentissage (ML) et l'apprentissage profond (DL). De cette façon, nous assistons à des scénarios où les JN aident à la transformation des technologies géospatiales et ces derniers aident à la grande émergence des JN.

Enfin, que le jumeau physique soit une infrastructure routière importante à surveiller, une zone à risque naturel à suivre, un écosystème naturel fragile à protéger ou tout autre patrimoine naturel ou architectural important à préserver, la technologie JN et ses piliers (géospatial, IoT, ML, etc.) vont être d'une grande aide pour optimiser et faciliter ce travail.

Références Bibliographiques

Abbas, A.; Khan, S.; Hussain, N.; Hanjra, M.A.; Akbar, S. (2013) Characterizing soil salinity in irrigated agriculture using a remote sensing approach. *Phys. Chem. Earth*, 55–57, 43–52.

Abdikan, S. (2018) Exploring image fusion of ALOS/PALSAR data and LANDSAT data to differentiate forest area. *Geocarto Int.* 2018, 33, 21–37.

Abedi, M.; Norouzi, G.-H.; Bahroudi, A. (2012) Support vector machine for multi-classification of mineral prospectivity areas. *Comput. Geosci.*, 46, 272–283.

Aboelnour, M., & Engel, B. A. (2018). Application of Remote Sensing Techniques and Geographic Information Systems to Analyze Land Surface Temperature in Response to Land Use/Land Cover Change in Greater Cairo Region, Egypt. *Journal of Geographic Information System*, 10(01), 57–88. <https://doi.org/10.4236/jgis.2018.101003>.

Abotalib, Z.; Sultan, M.; Elkadiri, R. (2016) Groundwater processes in Saharan Africa: Implications for landscape evolution in arid environments. *Earth-Sci. Rev.*, 156, 108–136.

Adam, E., O. Mutanga, J. Odindi, and E. M. Abdel-Rahman (2014) “Land-Use/Cover Classification in a Heterogeneous Coastal Landscape Using RapidEye Imagery: Evaluating the Performance of Random Forest and Support Vector Machines Classifiers.” *International Journal of Remote Sensing* 35 (10): 3440–3458. doi:10.1080/01431161.2014.903435.

Afzalan, N., Sanchez, T. W., & Evans-Cowley, J. (2017). Creating smarter cities: Considerations for selecting online participatory tools. *Cities*, 67, 21–30.

Aksoy, S., Koperski, K., Tusk, C., Marchisio, G., Tilton, J. C. (2005). Learning bayesian classifiers for scene classification with a visual grammar. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 581–589. <https://doi.org/10.1109/TGRS.2004.839547>.

Alaa Tharwat, A. (2019) Parameter investigation of support vector machine classifier with kernel functions, *knowl Inf Syst* 61, 1269–1302 (2019). <https://doi.org/10.1007/s10115-019-01335-4>.

Al-Jassar, H.K.; Rao, K.S. (2010) Monitoring of soil moisture over the Kuwait desert using remote sensing techniques. *IJRS* 2010, 31, 4373–4385.

Alonso, R., Borrás, M., Koppelaar, R., Lodigiani, A., Loscos, E. and Yöntem, E. (2019) SPHERE: BIM Digital Twin Platform Proceedings 2019, 20, 9; doi:10.3390/proceedings2019020009.

Altese, E.; Bolognani, O.; Mancini, M.; Troch, P. (1998) Retrieving soil moisture over bare soil from ERS 1 synthetic aperture radar data: Sensitivity analysis based on a theoretical surface scattering model and field data. *Water Resour. Res.*, 32, 653–661.

Ardiana, S.; Ahmad, A.; Kadir, O. (2000) Capability of Radarsat Data in Monsoon Flood Monitoring. *Proc. GIS Dev.*, 1–6.

Argialas, D., Harlow C. (1990) Computational Image Interpretation Models: An Overview and a Perspective. *Photogrammetric Engineering and Remote Sensing*, Vol. 56, No 6, June, pp. 871-886.

Ayala-Izurieta, J.E.; Márquez, C.O.; García, V.J.; Recalde-Moreno, C.G.; Rodríguez-Llerena, M.V.; Damián-Carrión, D.A. (2017) Land Cover Classification in an Ecuadorian Mountain Geosystem Using a Random Forest Classifier, Spectral Vegetation Indices, and Ancillary Geographic Data. *Geosciences*, 7, 34.

Azabdaftari, A. and Sunar F. (2016) Soil Salinity Mapping Using Multitemporal Landsat Data, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLI-B7, XXIII ISPRS Congress, 12–19 July 2016, Prague, Czech Republic.

Baghdadi, N.; Gaultier, S.; King, C. (2002) Retrieving surface roughness and soil moisture from synthetic aperture radar (SAR) data using neural networks. *Can. J. Remote Sens.*, 28, 701–711.

Baghdadi, N.; Holah, N.; Zribi, M. (2006) Soil moisture estimation using multi-incidence and multi-polarization ASAR data. *Int. J. Remote Sens.* 2006, 27, 1907–1920.

Bannari, A.; Ghadeer, A.; El-Battay, A.; Hameid, N.A.; Rouai, M. (2016b) Detection of Areas Associated with Flash Floods and Erosion Caused by Rainfall Storm Using Topographic Attributes, Hydrologic Indices, and GIS. In *Global Changes and Natural Disaster Management: Geo-information Technologies*; Springer International Publishing AG: Cham, Switzerland; Chapter: 13.

Bannari, A.; Kadhem, G.; El-Battay, A.; Hameid, N.A.; Rouai, M. (2016a) Assessment of Land Erosion and Sediment Accumulation Caused by Runoff after a Flash-Flooding Storm Using Topographic Profiles and Spectral Indices. *Adv. Remote Sens.*, 5, 315–354.

Bannari, A.; Ozbakir, B.A.; Langlois, A. (2007) Spatial Distribution Mapping of Vegetation Cover in Urban Environment Using TDVI for Quality of Life Monitoring. *Int. Geosci. Remote Sens.*, 679–682.

Barber, D.G.; Hochheim, K.P.; Dixon, R.; Moss crop, D.R.; McMullan, M.J. (1996) The role of Earth observation technologies in flood mapping: A Manitoba case study. *Can. J. Remote Sens.* 1996, 22, 137–143.

Barbouchi, M.; Riadh, A.; Chokmani, K.; Ben Aissa, N.; Lhissou, R.; El Harti, A. (2014) Soil Salinity Characterization Using Polarimetric InSAR Coherence: Case Studies in Tunisia and Morocco. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 8, 3823–3832.

Bassier, M., Vergauwen, M. and Van Genechten, B. (2016) Automated Semantic Labelling of 3D Vector Models for Scan-to-BIM. 4th Annual International Conference on Architecture and Civil Engineering (ACE 2016) (April), pp. 93–100.

- Bayarjargal, Y.; Karnieli, A.; Bayasgalan, M.; Khudulmur, S.; Gandush, C.; Tucker, C.J. (2006) A comparative study of NOAA–AVHRR derived drought indices using change vector analysis. *Remote Sens. Environ.* 2006, 105, 9–22.
- Becerril-Pi, R.; Mastachi-Loza, C.A.; Gonzalez-Sosa, E.; Díaz-Delgado, C.; Khalidou, M.B. (2015) Assessing desertification risk in the semi-arid highlands of central Mexico. *J. Arid Environ.*, 120, 4–13.
- Becker, F.; Choudhury, B.J. (1988) Relative sensitivity of normalized difference vegetation Index (NDVI) and microwave polarization difference Index (MPDI) for vegetation and desertification monitoring. *Remote Sens. Environ.*, 24, 297–311.
- Belgiu, M., and L. Drăguț. (2016) Random Forest in Remote Sensing: A Review of Applications and Future Directions. *ISPRS Journal of Photogrammetry and Remote Sensing* 114: 24–31. doi:10.1016/j.isprsjprs.2016.01.011.
- Benchelha, S., Aoudjehane, H. C., Hakdaoui, M., El Hamdouni, R., Mansouri, H., Benchelha, T., Layelmam, M., Alaoui, M. (2019) Landslide Susceptibility Mapping: A Comparison between Logistic Regression and Multivariate Adaptive Regression Spline Models in the Municipality of Oudka, Northern of Morocco, *World Academy of Science, Engineering and Technology International Journal of Geotechnical and Geological Engineering* Vol:13, No:5.
- Benedek, C., Shadaydeh, M., Kato, Z., Szir'anyi, T., Zerubia, J. (2015) Multilayer Markov Random Field models for change detection in optical remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing* 107, 22–37.
- Benediktsson, J. A. and Swain, P. H. (1990) Statistical Methods and Neural Network Approaches for Classification of Data from Multiple Sources. PhD thesis, Purdue Univ., School of Elect. Eng., West Lafayette, IN.

- Bennas, N.; Himmi, O.; Benamar, L.; L'Mohdi, O. (2016) Première données sur les coléoptères et les hémiptères aquatiques de la Sebkha d'Imlili (Région Dakhla-Oued ed Dahab, Sud-Ouest du Maroc). *Boletín Sociedad Entomológica Aragonesa (SEA)*, 59, 117–126.
- Berhane, T.M., Lane, C.R., Wu, Q. , Autrey, B.C., Anenkhonov, O.A., Chepinoga, V.V. and Liu, H. (2018a) Decision-Tree, Rule-Based, and Random Forest Classification of High-Resolution Multispectral Imagery for Wetland Mapping and Inventory. *Remote Sens.* 2018, 10, 580; doi:10.3390/rs10040580.
- Berhane, T.M., Lane, C.R., Wu, Q., Bradley, C. Autrey, B.C. et al.(2019) Decision-Tree, Rule-Based, and Random Forest Classification of High-Resolution Multispectral Imagery for Wetland Mapping and Inventory, *Remote Sens.* 2019, 10, 580; doi:10.3390/rs10040580.
- Berhane, T.M.; Lane, C.R.; Wu, Q.; Anenkhonov, O.A.; Chepinoga, V.V.; Autrey, B.C.; Liu, H. (2018b) Comparing pixel- and object-based approaches in effectively classifying wetland-dominated landscapes. *Remote Sens.* 2018, 10, 46.
- Berutti, M. (2019) Understanding the Digital Twin. Disponible en ligne: <https://www.chemengonline.com/understanding-the-digital-twin> (accédé le 10 janvier 2020).
- Biljecki, F.; Stoter, J.; Ledoux, H.; Zlatanova, S.; Çöltekin, A. (2015) Applications of 3D city models: State of the art review. *ISPRS Int. Geo-Inf.*, 4, 2842–2889.
- Bleeker, P. (1865) *Atlas Ichthyologique des Indes Orientales Néerlandaises*; Frédéric Muller: Amsterdam, The Netherlands; pp. 49–101.
- Blumberg, D.G. (1998) Remote sensing of desert dune forms by polarimetric synthetic aperture radar (SAR). *Remote Sens. Environ.*, 65, 204–216.
- Bolles, R. C. and Fischler. M. A. (1981) A RANSAC-Based Approach to Model Fitting and Its Application to Finding Cylinders in Range Data. *IJCAI*.
- Booth, D.T., Cox, S.E., (2009). Dual-camera, high-resolution aerial assessment of pipeline revegetation. *Environ. Monit. Assess.* 158, 23–33.

Boschert, S. and Rosen, R. (2016). Digital Twin—The Simulation Aspect. In Peter Hehenberger, David Bradley (Eds.): Mechatronic Futures. Cham: Springer International Publishing, pp. 59–74.

Bouaziz, M.; Matschullat, J.; Gloaguen, R. (2011) Improved remote sensing detection of soil salinity from a semi-arid climate in northeast Brazil. *Comptes Rendus Geosci.*, 343, 795–803.

Breiman, L. (2001). “Random Forests.” *Machine Learning* 54 (1): 5–32.
doi:10.1023/A:1010933404324.

Breiman, L., (2002) Manual on setting up, using, and understanding random forests V3.1, https://www.stat.berkeley.edu/~breiman/Using_random_forests_V3.1.pdf,

Brettel, M., Friederichsen, N., Keller, M., Rosenberg, M. (2014) How Virtualization, Decentralization and Network Building Change the Manufacturing Landscape: An Industry 4.0 Perspective, *Int. J. Mech. Aerospace, Ind. Mechatronics Eng.* 8 (2014) 37–44

Brosofske, K.D.; Froese, R.E.; Falkowski, M.J.; Banskota, A. (2013) A review of methods for mapping and prediction of inventory attributes for operational forest management. *For. Sci.* 2013, 60, 733–756.

Brown, M., Lewis, H.G., and Gunn, S.R. (2000) Linear Spectral Mixture Models and Support Vector Machines for Remote Sensing. *IEEE Transactions On Geoscience And Remote Sensing*, Vol. 38, No. 5, September 2000.

Brownlee, J. (2013) Basics of Linear Algebra for Machine Learning, Discover the Mathematical Language of Data in Python, Ebook 211pp.

Bryant, R.G.; Gilvear, D.J. (1999) Quantifying geomorphic and riparian land cover changes either side of a large flood event using airborne remote sensing: River Tay, Scotland. *Geomorphology* 1999, 29, 307–321.

Buyuksalih, G., Bayburt, S., Baskaraca, P., Buyuksalih, I., and A. Abdul-Rahman (2018). 3D city modelling of Istanbul city based on LiDAR data and panoramic images – issues and challenges. Tutorial at GGT 2018 International Conference, Kuala Lumpur, Malaysia.

Calvo-Zaragoza, J., Valero-Mas, J. J., Rico-Juan, J. R. (2015). Improving kNN multi-label classification in Prototype Selection scenarios using class proposals. *Pattern Recognition*, 48(5), 1608–1622. <https://doi.org/10.1016/J.PATCOG.2014.11.015>.

Campbell, J.B., Wynne, R.H., (2011) *Introduction to Remote Sensing*, fifth ed. The Guilford Press, New York.

Campolo, M.; Andreussi, P.; Soldati, A. (2003) Artificial neural network approach to flood forecasting in the river Arno. *Hydrol. Sci. J.*, 48, 381–398.

Candade, N., (2004) Multispectral classification of Landsat images: a comparison of support vector machine and neural network classifiers. *ASPRS Annual Conference Proceedings*, Denver, Colorado.

Chander, G.; Markham, B.L.; Helder, D.L. (2009) Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. *Remote Sens. Environ.*, 113, 893–903.

Chang, C.-C. and Lin, C.-J. (2011) LIBSVM: A library for support vector machines. *ACM Trans. Intell. Syst. Technol.* 2011, 2, 1–27.

Chapelle, O., Bousquet, O. (2002). Choosing Multiple Parameters for Support Vector Machines (Vol. 46). Retrieved from <https://link.springer.com/content/pdf/10.1023%2FA%3A1012450327387.pdf>.

Chaperon, T., Goulette, F. (2001) Extracting Cylinders in Full 3D Data Using a Random Sampling Method and the Gaussian Image. *Proceedings of the Vision Modeling and Visualization Conference 2001 (VMV-01)*, Stuttgart, Germany, November 21-23, 2001

Chauhan, S.; Srivastava, H.S. (2016) Comparative evaluation of the sensitivity of multi-polarised sar and optical data for various land cover. *Int. J. Adv. Remote Sens.*, 4, 1–14.

Chavez, W.J.; Sides, S.C.; Anderson, J.A. (1991) Comparison of three different methods to merge multiresolution and multispectral data: TM & Spot Pan. *Photogramm. Eng. Remote Sens.* 1991, 57, 295–303.

Chen, C.F.; Valdez, M.C.; Chang, N.B.; Chang, L.Y.; Yuan, P.Y. (2014) Monitoring Spatiotemporal Surface Soil Moisture Variations during Dry Seasons in Central America With Multisensor Cascade Data Fusion. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 7, 4340–4355.

Chen, J., Chen, Y., Du, X., Li, C., Lu, J., Zhao, S., & Zhou, X. (2013). Big data challenge: A data management perspective. *Frontiers of Computer Science*, 7(2), 157–164. doi:10.1007/s11704-013-3903.

Chen, J., Xiang, J., Hu, Q.(2016a) Quantitative geoscience and geological big data development: a review. *Acta Geologica Sinica*, vol. 90, no. 4, pp. 1490–1515, 2016.

Chen, J.; Gong, P.; He, C.; Pu, R.; Shi, P. (2003) Land-use/land-cover change detection using improved change-vector analysis. *Photogram. Eng. Remote Sens.*, 69, 369–379.

Chen, S.; Xu, B.; Jin, Y.; Huang, Y.; Zhang, W.; Guo, J.; Shen, G.; Yang, X. (2016b) Remote Sensing Monitoring and Spatial-temporal Characteristics Analysis of Soil Salinization in Agricultural Area of Northern Xinjiang. *Acta Geogr. Sin.*, 35, 1607–1615.

Chignell, S.; Anderson, R.; Evangelista, P.; Laituri, M.; Merritt, D. (2015) Multi-temporal independent component analysis and Landsat 8 for delineating maximum extent of the 2013 Colorado front range flood. *Remote Sens.*, 7, 9822–9843.

Clement, M.A.; Kilsby, C.G.; Moor, P. (2017) Multi-temporal synthetic aperture radar flood mapping using change detection. *J. Flood Risk Manag.*, 11, 152–168.

Cloude, S.; Papathanassiou, K. (1998) Polarimetric SAR Interferometry. *IEEE Trans. Geosci. Remote Sens.* 1998, 36, 1551–1565.

Colditz, R. (2015) An evaluation of different training sample allocation schemes for discrete and continuous land cover classification using decision tree-based algorithms. *Remote Sens.* 7, 9655. Computational Foundations, 3rd ed.; Academic Press: New York, NY, USA.

Corcoran, J.; Knight, J.; Gallant, A. (2013) Influence of multi-source and multi-temporal remotely sensed and ancillary data on the accuracy of random forest classification of wetlands in Northern Minnesota. *Remote Sens.*, 5, 3212–3238.

Cortes, C., and V. Vapnik. (1995) Support-Vector Networks. *Machine Learning* 20: 273–297. doi:10.1007/BF00994018.

Costin, A. (2016) A New Methodology for Interoperability of Heterogeneous Bridge Information Models. Ph.D. Thesis, Georgia Institute of Technology, Atlanta, GA, USA.

Costin, A.; Adibfar, A.; Hu, H.; Chen, S.S. (2018) Building information modelling (BIM) for transportation infrastructure-Literature review, application, challenges, and recommendations. *Autom. Constr.*, 94, 257–281.

Dalla Mura, M., Villa, A., Benediktsson, J.A., Chanussot, J., Bruzzone, L. (2011) Classification of Hyperspectral Images by Using Extended Morphological Attribute Profiles and Independent Component Analysis. *IEEE Geoscience and Remote Sensing Letters*, 8: 542-546. <http://dx.doi.org/10.1080/01431161.2010.512425>.

Dang, NS and Shim, CS (2018). BIM authoring for an image based bridge maintenance system of existing cable-supported bridges, *IOP Conference Series: Earth and Environmental Science*, 143(1): 012032.

Daniel, S., Doran, M.-A., (2013) GeoSmartCity: geomatics contribution to the smart city. In: *Proceedings of the 14th Annual International Conference on Digital Government Research*, pp. 65–71.

Daniels, J.; Blumberg, D.G.; Linetsky, M.; Vulfson, L.D.; Kotlyar, A.L.; Freiliker, V.; Ronen, G. (2003) Microwave remote sensing of physically buried objects; implications for environmental research. *Remote Sens. Environ.*, 86, 243–256.

Dietterich, T.G. (2000) An experimental comparison of three methods for constructing ensembles of decision trees: bagging, boosting, and randomization. *Mach. Learn.* 40, 139–157.

Dimitrov, P., Dong, Q., Eerens, H., Gikov, A., Filchev, L., Roumenina, E. and Jelev, G.(2019) Sub-Pixel Crop Type Classification Using PROBA-V100 m NDVI Time Series and Reference Data from Sentinel-2 Classifications.

Dobos, E. (2007) *Albedo Encyclopedia of Soil Science*, 2nd ed.; Rattan Lal CRC 2003; Springer: Berlin, Germany; ISBN: 978-0-8493-3830-4 eBook ISBN 978-1-4398-7062-4.

Dobson, M.C.; Pierce, L.E.; Ulaby, F.T. (1997) The role of frequency and polarization in terrain classification using SAR data. *IEEE Trans. Geosci. Remote Sens.*, 35, 1621–1623.

Dobson, M.C.; Ulaby, F.T. (1998) Mapping soil moisture distribution with imaging radar. In *Principles & Applications of Imaging Radar, Manual of Remote Sensing*, 3rd ed.; Henderson, F.M., Lewis, A.J., Eds.; JohnWiley & Sons, Inc.: New York, NY, USA, 1998; ISBN 0-47129-406-3.

Dolman, A.J.; Gash, J.H.C.; Goutorbe, J.-P.; Kerr, Y.; Lebel, T.; Prince, S.D.; Stricker, J.N.M. (1997) The role of the land surface in Sahelian climate: HAPEX-Sahel results and future research needs. *J. Hydrol.*, 188–189, 1067–1079.

Dong, F.; Tang, Y.; Xing, X.; Liu, Z.; Xing, L. (2019) Formation and Evolution of Soil Salinization in Shouguang City Based on PMS and OLI/TM Sensors. *Water*, 11, 345.

Donkers, S. (2013) Automatic generation of CityGML LoD3 building models from IFC models. Delft University of Technology, The Netherlands.

- Donkers, S., Ledoux, H., Zhao, J., & Stoter, J. (2016). Automatic conversion of IFC datasets to geometrically and semantically correct CityGML LOD3 buildings. *Transactions in GIS*, 20(4), 547–569. <https://doi.org/10.1111/tgis.12162>
- Douaoui, A.E.K.; Nicolasb, H.; Walter, C. (2006) Detecting Salinity Hazards within a Semiarid Context by Means of Combining Soil and Remote-Sensing Data. *Geoderma*, 134, 217–230.
- Doubková, M.; Van Dijk, A.I.; Sabel, D.; Wagner, W.; Blöschl, G. (2012) Evaluation of the predicted error of the soil moisture retrieval from C-band SAR by comparison against modelled soil moisture estimates over Australia. *Remote Sens. Environ.* 2012, 120, 188–196.
- Douillard, B.; Underwood, J.; Vlaskine, V.; Quadros, A.; Singh, S. (2010) A Pipeline for the Segmentation and Classification of 3d Point Clouds. In *Proceedings of the 12th International Symposium on Experimental Robotics (ISER 2010)*, New Delhi and Agra, India, 18–21 December 2010.
- Dwivedi, R.S.; Rso, B.R.M. (1992) The selection of the best possible Landsat TM band combination for delineating salt-affected soils. *Int. J. Remote Sens.*, 13, 2051–2058.
- Elachi, C. (1987) *Spaceborne Radar Remote Sensing: Applications and Techniques*; The Institute of Electrical and Electronics Engineers: New York, NY, USA.
- Elbelrhiti, H.; Phillipe, P.; Andreotti, B. (2005) Field evidence for surface-wave-induced instability of sand dunes. *Nature*, 437, 720–723.
- El-Zeiny, A.M.; Effat, H.A. (2017) Environmental monitoring of spatiotemporal change in land use/land cover and its impact on land surface temperature in El-Fayoum governorate, Egypt. *Remote Sens. Appl. Soc. Environ.* 2017, 8, 266–277.
- Emran, A. (2016) Le fonctionnement de la Sebkha d’Imlily dévoilé par les images Radar Palsar. Un reliquat de passé dans le Sahara marocain témoin de changement climatique dans des conditions géologiques improbables. In *Conférence Régionale « Initiation et*

Développement de Cartographie Géospatiale Via le Web Pour la Mutualisation et le Partage de L'information Géospatiale»; EMI: Rabat, Morocco.

Emran, A.; Hakdaoui, M.; Chorowicz, J. (1996a) Anomalies on geologic maps from multispectral and textural classification: The bleida mining district (Morocco). *Remote Sens. Environ.* 1996, 57, 13–21.

Emran, A.; Hakdaoui, M.; Chorowicz, J. (1996b) Spectral signatures and textures in geological mapping by direct HRV-XS classification of SPOT images of deserts-The mining sector of Zgounder (Anti-Atlas, Morocco). *Int. J. Remote Sens.* 1996, 17, 863–877.

Essefi, E.; Gharsalli, N.; Kalabi, S.; Ben Ameer, M.; Yaich, C. (2015) Spectral Analysis of a Core from the Sebkha of Sidi Mansour, Southern Tunisia: The Holocene Cyclostratigraphy. *J. Remote Sens. GIS* 2015, 4, 141.

Evans, D.L.; Farr, T.G.; van Zyl, J.J.; Zebker, H.A. (1998) Radar polarimetry: Analysis tools and applications. *IEEE Trans. Geosci. Remote Sens.*, 26, 774–789.

Evans, G.; St. Clement Kendall, C.G.; Skipwith, P. (1964) Origin of the coastal flats, the Sebkha, the Trucial coast, Persian Gulf. *Nature*, 202, 759–761.

Farrar, C. R. and Worden, K. (2013) Structural health monitoring: A machine learning perspective. John Wiley and Sons, 2013.

Fauvel, M., Benediktsson, J.A., Chanussot, J., Sveinsson, J.R. (2008) Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing* 46 (11), 3804–3814.

Fauvel, M., Chanussot, J., Benediktsson, J.A. (2009) Kernel principal component analysis for the classification of hyperspectral remote sensing data over urban.

Feng, Q.; Liu, J.; Gong, J. (2015) Urban Flood Mapping Based on Unmanned Aerial Vehicle Remote Sensing and Random Forest Classifier—A Case of Yuyao, China. *Water*, 7, 1437–1455.

Feyisa, G.L.; Meilby, H.; Fensholt, R.; Proud, S.R. (2014) Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery. *Remote Sens. Environ.* 2014, 140, 23–35.

Fisher, A.; Flood, N.; Danaher, T. (2016) Comparing Landsat water index methods for automated water classification in eastern Australia. *Remote Sens. Environ.*, 175, 167–182.

Flood, N. (2014) Continuity of reflectance data between Landsat-7 ETM+ and Landsat-8 OLI, for both Top-of-Atmosphere and surface reflectance: A study in the Australian landscape. *Remote Sens.* 2014, 6, 7952–7970.

Foody, G.M. (2004) Supervised image classification by MLP and RBF neural networks with and without an exhaustively defined set of classes. *Int. J. Remote Sens.*, 25, 3091–3104.

Foody, G.M. and A. Mathur, (2004) A Relative Evaluation of Multiclass Image Classification by Support Vector Machines. *IEEE Transactions On Geoscience And Remote Sensing*, Vol. 42, No. 6, June 2004.

Foschi, P.G.; Smith, D.K. (1997) Detecting subpixel woody vegetation in digital imagery using two artificial intelligence approaches. *Photogramm. Eng. Remote Sens.*, 63, 493–500.

Foucault, A. (1994) La révolution paléoclimatologique. *Géochronique* 1994, 50, 13–14.

Gaber, A.; Koch, M.; El-Baz, F. (2010) Textural and compositional characterization of Wadi Feiran Deposits, Sinai Peninsula, Egypt, using Radarsat-1, PALSAR, SRTM and ETM+ data. *J. Remote Sens.*, 2, 52–75.

Gan, T.Y.; Zunic, F.; Kuo, C.-C.; Strobi, T. (2012) Flood mapping of Danube River at Romania using single and multi-date ERS2-SAR images. *Int. J. Appl. Earth Obs. Geoinf.*, 18, 69–81.

- Gianinetto, M.; Villa, P.; Lechi, G. (2006) Post-flood damage evaluation using Landsat TM and ETM+ data integrated with DEM. *IEEE Trans. Geosci. Remote Sens.*, 44, 236–243.
- Gislason, P.O.; Benediktsson, J.A.; Sveinsson, J.R. (2006) Random Forests for land cover classification. *Pattern Recognit. Lett.* 2006, 27, 294–300.
- González, A.R., Zanin, M., Ernestina, M.R. (2019) Public Health and Epidemiology Informatics: Can Artificial Intelligence Help Future Global Challenges? An Overview of Antimicrobial Resistance and Impact of Climate Change in Disease Epidemiology, *IMIA Yearbook of Medical Informatics*.
- Goodfellow, I.; Bengio, Y.; Courville, A. (2016) *Deep Learning: Adaptive Computation and Machine Learning*; MIT Press: London, UK, 2016.
- Google Earth Engine (2012) A Planetary-Scale Plat-Form for Environmental Data & Analysis. 2012. Disponible en ligne: <https://earthengine.google.org> (accédé le 8 Aout 2019).
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R. (2017) Google Earth Engine: Planetary-scale geospatial data analysis for everyone. *Rem. Sens. Of Env.* 202:18-27.
- Grieves, M. (2014) *Digital Twin: Manufacturing Excellence through Virtual Factory Replication*; A White Paper; Michael Grieves, LLC: Melbourne, FL, USA, 2014.
- Grieves, M. and Vickers, J. (2001) *Digital Twin: Mitigating Unpredictable, Undesirable Emergent Behavior in Complex Systems*.
- Grilli, E., Menna, F., and Remondino, F. (2017) A Review of Point Clouds Segmentation and Classification Algorithms. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII- 2/W3(March):339–344.
- Gruen, A., (2013) Next generation smart cities-the role of geomatics. *BBC 26.17: 32.81 G 547 (25)*, 25.

Gstaiger, V., Tian, J., Kiefl, R., Kurz, F. (2018) 2D vs. 3D Change Detection Using Aerial Imagery to Support Crisis Management of Large-Scale Events. *Remote Sens.*, 10, 2054; doi:10.3390/rs10122054.

Guan, H.; Li, J.; Cao, S.; Yu, Y. (2016) Use of mobile LiDAR in road information inventory: A review. *Int. J. Image Data Fusion* , 7, 219–242.

Guo, Y.; Bennamoun, M.; Sohel, F.; Lu, M.; Wan, J. (2014) 3D Object Recognition in Cluttered Scenes with Local Surface Features: A Survey. *IEEE Trans. Pattern Anal. Mach. Intell.* 2014, 36, 2270–2287.

Guru, B. and Aravind, S. M. (2015). Land use land cover changes in pre- and postearthquake affected area using geoinformatics - Western Coast of Gujarat, India. *Disaster Advances*, 8(4), 1–14.

Haas, J. (2010) Soil Moisture Modelling Using TWI and Satellite Imagery in the Stockholm Region. Master's Thesis, School of Architecture and the Built Environment, Royal Institute of Technology (KTH), Stockholm, Sweden, 2010.

Hadi, G. M., Salman, N. H. (2016) Image Segmentation Based on Single Seed Region Growing Algorithm, *ZJPAS*: 2016, 28(2): s120-126.

Haidara, I., Tahri, M., Maanan, M., Mustapha, H. (2019) Efficiency of Fuzzy Analytic Hierarchy Process to detect soil erosion vulnerability, DOI: 10.1016/j.geoderma.2019.07.011

Hakdaoui, S.; Emran, A. (2019) Extraction of water information based on SAR RADAR and Optical image processing: Case of flood disaster in Southern Morocco. In *Geospatial Technology, Application in Water Resources Management, Series: Advances in Science, Technology & Innovation*; Springer: Cham, Switzerland.

Hakdaoui, S.; Emran, A.; Pradhan, B.; Chang-Wook Lee, C.W.; Nguemhe Fils, S.C. (2019) A Collaborative Change Detection Approach on Multi-Sensor Spatial Imagery for Desert

Wetland Monitoring after a Flash Flood in Southern Morocco. *Remote Sens.* 2019, 11, 1042; doi:10.3390/rs11091042.

Hakdaoui, S.; Emran, A.; Pradhan, B.; Qninba, A.; Balla, T.E.; Mfondoum, A.H.N.; Lee, C.-W.; Alamri, A.M. (2020) Assessing the Changes in the Moisture/Dryness of Water Cavity Surfaces in Imlili Sebkha in Southwestern Morocco by Using Machine Learning Classification in Google Earth Engine. *Remote Sens.* 12, 131.

Ham, J., Chen, Y., Crawford M., and Ghosh J. (2005) Investigation of the random forest framework for classification of hyperspectral data. *IEEE Trans. Geosci. Remote Sens.*, 43(3):492–501, March.

Hammam, A.A.; Mohammed, E.S. (2018) Mapping soil salinity in the East Nile Delta using several methodological approaches of salinity assessment. *Egypt. J. Remote Sens. Space Sci.* 2018.

Hansch, R. and Hellwich, O. (2016) When to fuse what? random forest based fusion of low-, mid-, and high-level information for land cover classification from optical and sar images. In *IEEE IGARSS*, pages 3587–3590, July.

Harris, J. R. and Grunsky, E. C. (2015) “Predictive lithological mapping of Canada’s North using Random Forest classification applied to geophysical and geochemical data,” *Comput. Geosci.* 80, 9–25.

Harwood, T. D., R. J. Donohue, K. J. Williams, S. Ferrier, T. R. McVicar, G. Newell, (2016) Habitat Condition Assessment System: a new way to assess the condition of natural habitats for terrestrial biodiversity across whole regions using remote sensing data. *Methods Ecol. Evol.* 7, 1050–1059.

He, Y., E. Lee, and T. A. Warner. (2017) A Time Series of Annual Land Use and Land Cover Maps of China from 1982 to 2013 Generated Using AVHRR GIMMS NDVI3g Data. *Remote Sensing of Environment* 199: 201–217. doi:10.1016/j.rse.2017.07.010.

Henry, F., Herwindiati D.E., Mulyono S. Hendryli J. (2017) Sugarcane Land Classification with Satellite Imagery using Logistic Regression Model, IOP Conf. Series: Materials Science and Engineering 185 012024 doi:10.1088/1757-899X/185/1/012024.

Hepi, H. Handayani, H. H., Murayama, Y., Ranagalage, M. , Liu, F. and Dissanayake, D. (2018) Geospatial Analysis of Horizontal and Vertical Urban Expansion Using Multi-Spatial Resolution Data: A Case Study of Surabaya, Indonesia. Remote Sens., 10, 1599; doi:10.3390/rs10101599.

Heydari, S. S., Mountrakis, G. (2018). Effect of classifier selection, reference sample size, reference class distribution and scene heterogeneity in per-pixel classification accuracy using 26 Landsat sites. Remote Sensing of Environment, 204, 648–658. <https://doi.org/10.1016/j.rse.2017.09.035>.

Hostache, R.; Matgen, P.; Wagner, W. (2012) Change detection approaches for flood extent mapping: How to select the most adequate reference image from online archives? Int. J. Appl. Earth Obs. Geoinf., 19, 205–213.

Hsu, K.L.; Gao, X.; Sorooshian, S.; Gupta, H.V. (1997) Precipitation estimation from remotely sensed information using artificial neural networks. J. Appl. Meteorol., 36, 1176–1190.

Hsu, K.L.; Gupta, H.V.; Sorooshian, S. (1995) Artificial neural network modelling of the rainfall-runoff process. Water Resour. Res., 31, 2517–2530.

Huang, C., Davis L. S., and Townshend, J. R. G. (2002) An assesement of support vector machines for land cover classifiocation,” Int. J. Remote sensing, vol. 23, no. 4, pp. 725–749, 2002.

Huang, G.-B., Zhou, H., Ding, X., & Zhang, R. (2012). Extreme learning machine for regression and multiclass classification. IEEE Transactions on Systems, Man, and Cybernetics. Part B, Cybernetics, 42(2), 513–529. <https://doi.org/10.1109/TSMCB.2011.2168604>.

- Imrie, C.E.; Durucan, S.; Korre, A. (2000) River flow prediction using artificial neural networks: Generalizations beyond the calibration range. *J. Hydrol.* 2000, 233, 138–153.
- Ioannidou, A.; Chatzilari, E.; Nikolopoulos, S.; Kompatsiaris, I. (2017) Deep Learning Advances in Computer Vision with 3d Data: A Survey. *ACM Comput. Surv. CSUR* 2017, 50, 20.
- Jackson, Q., Landgrebe, D.A. (2002) Adaptive Bayesian Contextual Classification Based on Markov Random Fields. *IEEE Transactions on Geoscience and Remote Sensing*, 40: 2454-2463. doi: <http://dx.doi.org/10.1109/TGRS.2002.805087>.
- Jackson, T.J. (1997) Soil moisture estimation using spatial satellite microwave/imager satellite data over a grassland region. *Water Resour. Res.*, 33, 1475–1484. [CrossRef]
- Jarar Oulidi, H. (2019) Données spatiales sur l'eau, technologies géospatiales et gestion des données, livre ISTE édition, collection écologique, 176p.
- Jarar Oulidi, H., Fadil, A., Semane, N. (2020) Geospatial Technology. *Advances in Science, Technology & Innovation (IEREK Interdisciplinary Series for Sustainable Development)*. Springer, Cham.
- Jarar Oulidi, H., Moumen, A. (2015) Towards a Spatial Data Infrastructure and an Integrated Management of Groundwater Resources, *Journal of Geographic Information System*, 7, 667-676, <http://dx.doi.org/10.4236/jgis.2015.76054>.
- Javelle, P.; Demmargne, J.; Defrance, D.; Pansu, J.; Arnaud, P. (2014) Evaluating flash flood warnings at ungauged locations using post-event surveys: A case study with the AIGA warning system. *Hydrol. Sci. J.* 2014, 59, 1390–1402.
- Jayapriya, P., Hemalatha, S. (2019) Comparative Analysis Of Image Segmentation Techniques And Its Algorithm, *INTERNATIONAL JOURNAL OF SCIENTIFIC & TECHNOLOGY RESEARCH VOLUME 8, ISSUE 10, OCTOBER*.

Jensen, J.R. (2000) *Remote Sensing of the Environment: An Earth Resource Perspective*; Prentice-Hall: Upper Saddle River, NJ, USA.

Johansen, K.; Phinn, S.; Taylor, M. (2015) Mapping woody vegetation clearing in Queensland, Australia from Landsat imagery using the Google Earth Engine. *Remote Sens. Appl. Soc. Environ.*, 1, 36–49.

Jones, M.O., Allred, B.W., Naugle, D.E., Maestas, J.D., Donnelly, P., Metz, L.J., Karl, J., Smith, R., Bestelmeyer, B., Boyd, C. (2018) Innovation in rangeland monitoring: annual, 30 m, plant functional type percent cover maps for US rangelands, 1984–2017. *Ecosphere* 9, e02430.

Kalantar, B.; Pradhan, B.; Naghibi, S.A.; Motevalli, A.; Mansor, S. (2018) Assessment of the effects of training data selection on the landslide susceptibility mapping: A comparison between support vector machine (SVM), logistic regression (LR) and artificial neural networks (ANN). *Geomat. Nat. Hazards Risk*, 9, 49–69.

Kamilaris, A.; Pitsillides, A. (2016) Mobile phone computing and the Internet of Things: A survey. *IEEE Internet Things (IoT) J.*, 3, 885–898.

Kanchi, S., Sandilya, S., Ramkrishna, S., Manjrekar, S., & Vhadgar, A. (2015). Challenges and solutions in big data management – an overview. Paper presented at the 3rd International Conference on Future Internet Of Things And Cloud (Ficloud) And International Conference on Open And Big (Obd), Rome, Italy, August 24–26.

Kanellopoulos, I., Wilkinson, G., and Moons, T. (1999). *Machine Vision and Advanced Image Processing in Remote Sensing*. Springer Verlag.

Kang, T. W., & Hong, C. H. (2015). A study on software architecture for effective BIM/GIS-based facility management data integration. *Automation in Construction*, 54, 25–38. <https://doi.org/10.1016/j.autcon.2015.03.019>

- Kavzoglu, T., and I. Colkesen (2009) A Kernel Function Analysis for Support Vector Machines for Land Cover Classification. *International Journal of Applied Earth Observation and Geoinformation* 11 (5): 352–359. doi:10.1016/j.jag.2009.06.002.
- Kavzoglu, T.; Mather, P.M. (2003) The use of backpropagating artificial neural networks in land cover classification. *Int. J. Remote Sens.*, 24, 4907–4938.
- Keshava, N. (2003) A survey of spectral unmixing algorithms. *Lincoln Lab. J.*, 14:55–78, 2003.
- Kettig, R.L., Landgrebe, D.A. (1976) Classification of Multispectral Image Data by Extraction and Classification of Homogeneous Objects. *IEEE Transactions on Geoscience Electronics*, 14: 19-26. doi: <http://dx.doi.org/10.1109/TGE.1976.294460>.
- Kim, C., Kim, B., Kim, H., (2013) 4D CAD model updating using image processing based construction progress monitoring. *Autom. Construct.* 35, 44–52.
- Kim, G.; Barros, A.P. (2001) Quantitative flood forecasting using multisensory data and neural networks. *J. Hydrol.*, 246, 45–62.
- Koch, M.; El-Baz, F. (2000) Spectral and textural classification of active wadi systems in arid lands by Landsat TM and Radarsat data. In *Proceedings of the CDROM-Proceedings of the ASPRS Annual Conference, Washington, DC, USA, 19–26 April*; p. 10.
- Kotsiantis, S. (2011) Combining bagging, boosting, rotation forest and random subspace methods. *Artif. Intell. Rev.*, 35, 223–240.
- Kotsiantis, S.B. (2007) 'Supervised machine learning: a review of classification techniques', *Informatica*, vol. 31, pp. 249-268.
- Kranjcic, N., Medak, D., Župan, R., Rezo, M. (2019) Support Vector Machine Accuracy Assessment for Extracting Green Urban Areas in Towns. *Remote Sens*, 11, 655; doi:10.3390/rs11060655.

Kritzinger, W., Karner, M., Traar, G., Henjes, J., Sihn, W. (2018) Digital Twin in manufacturing: A categorical literature review and classification.

Kumar, U., Ganguly, S., Nemani, R.R. (2019) Exploring Subpixel Learning Algorithms for Estimating Global Land Cover Fractions from Satellite Data Using High Performance Computing. *Remote Sens*, 9, 1105; doi:10.3390/rs9111105.

Kumar, V.; Agrawal, P.; Agrawal, S. (2017) ALOS PALSAR and Hyperion Data Fusion for Land Use Land Cover Feature Extraction. *J. Indian Soc. Remote Sens.* 2017, 45, 407–416.

Lacava, T.; Filizzola, C.; Pergola, N.; Sannazzaro, F.; Tramutoli, V. (2010) Improving flood monitoring by the Robust AVHRR Technique (RAT) approach: The case of the April 2000 Hungary flood. *Int. J. Remote Sens.*, 31, 2043–2062.

Landgrebe, D.A. (2003) Signal theory methods in multispectral remote sensing. John Wiley & Sons, Incorporation. School of Electrical & Computer Engineering Purdue University West Lafayette, IN 47097-1285.

Landrieu, L., Raguet, H., Vallet, B., Mallet, C. and Weinmann, M. (2017). A structured regularization framework for spatially smoothing semantic labelings of 3D point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing* 132, pp. 102–118.

Laney, D (2001) 3D data management: Controlling data volume, velocity and variety, Gartner, Tech. Rep., Feb.

Lary, D. J., Alavi, A. H., Gandomi, A. H., and Walker, A. L.(2016) Machine learning in geosciences and remote sensing, *Geosci. Front.* 7(1), 3-10.

Lary, D.J. (2010) Artificial Intelligence in Geoscience and Remote Sensing. INTECH Open Access Publisher.

Lee, J., Bagheri, B., Kao, H. (2015) A Cyber-Physical Systems architecture for Industry 4 . 0-based manufacturing systems, *Manuf. Lett.* 3 18–23. doi:10.1016/j.mfglet.2014.12.001.

- Lee, J.-G. and Kang M. (2015). Geospatial big data: Challenges and opportunities. *Big Data Research*, 2(2), 74–81. doi:10.1016/j.bdr.2015.01.003.
- Lee, J.-S.; Pottier, E. (2009) *Polarimetric Radar Imaging: From Basics to Applications*; CRC Press: Boca Raton, FL, USA, 2009; 422p.
- Lévêque, C. (1990) Relict tropical fish fauna in Central Sahara. *Ichthyol. Explor. Freshw.* 1990, 1, 39–48.
- Li, Q. and Li, D. (2014). Big data GIS. *Wuhan Daxue Xuebao (Xinxi Kexue Ban)/Geomatics and Information Science of Wuhan University*, 39(6), 641–646. doi:10.13203/j.whugis20140150.
- Liaw, A., Wiener, M. (2002) Classification and regression by random forest, *R News*, 2(3).
- Lin, Y., Wang, C., Cheng, J., Chen, B., Jia, F., Chen, Z. and Li, J. (2015) Line segment extraction for large scale unorganized point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing* 102(March), pp. 172–183.
- Liu Y., Liu X., Gao S., Gong L., Kang C., Zhi Y. and Shi L. (2015a). Social sensing: A new approach to understanding our socioeconomic environments. *Annals of the Association of American Geographers*, 105(3), 512–530. doi:10.1080/00045608.2015.1018773.
- Liu, B.D. , Xie, W., Meng, J., Li, Y., Wang, Y. (2018) Hybrid Collaborative Representation for Remote-Sensing Image Scene Classification. *Remote Sens.*, 10, 1934; doi:10.3390/rs10121934.
- Liu, M.; Dai, Y.; Zhang, J.; Zhang, X.; Meng, J.; Xie, Q. (2015) PCA-based sea-ice image fusion of optical data by HIS transform and SAR data by wavelet transform. *Acta Oceanol. Sin.* 2015, 34, 59–67.
- Liu, X., Wang, X., Wright, G., Cheng, J., Li, X., & Liu, R. (2017). A State-of-the-Art Review on the Integration of Building Information Modeling (BIM) and Geographic Information

System (GIS). *ISPRS International Journal of Geo- Information*, 6(2), 53.
<https://doi.org/10.3390/ijgi6020053>

Liu, X.; Hu, G.; Chen, Y.; Li, X.; Xu, X.; Li, S.; Pei, F.; Wang, S. (2018) High-resolution multi temporal mapping of global urban land using Landsat images based on the Google Earth Engine Platform. *Remote Sens. Environ.*, 209, 227–239.

Lobell, D. B., Thau, D., Seifert, C., Engle, E., & Little, B. (2015). A scalable satellite-based crop yield mapper. *Remote Sensing of Environment*, 164, 324–333.
<https://doi.org/10.1016/j.rse.2015.04.021>.

Lobell, D.; Asner, G. (2002) Moisture Effects on Soil Reflectance. *Soil Sci. Am. J.*, 66, 722–727.

Lu, D., and Weng, Q. (2007) A survey of image classification methods and techniques for improving classification performance, *Int. J. Remote Sens.* 28(5), 823-870.

Lyu, H., Lu, H., Mou, L., Li, W., Li, X., Li, X., Wang, J., Zhu, X. X., Yu, L., and Gong, P. (2017) A deep information based transfer learning method to detect annual urban dynamics of Beijing and Newyork from 1984–2016. Conference: IGARSS 2017 - 2017 IEEE International Geoscience and Remote Sensing Symposium. DOI: 10.1109/IGARSS.2017.8127363

Ma, Y. , Wu, H. , Wang L., Huang B., Ranjand R. , Zomaya A., Jie W. (2015) - Remote sensing big data computing: Challenges and opportunities. *Future Generation Computer Systems*. 51:47-60.

Madni, A.M., Madni, C.C. and Lucero, S. D. (2019) Leveraging Digital Twin Technology in Model-Based Systems Engineering, *Systems* 2019, 7, 7; doi:10.3390/systems7010007.

Maggiori, E., Tarabalka, Y., Charpiat, G., and Alliez, P. (2017). High-resolution semantic labeling with convolutional neural networks. *arXiv*. [Online]. Available: <https://arxiv.org/abs/1611.01962>.

Mahdianpari, M.; Salehi, B.; Mohammadimanesh, F.; Homayouni, S.; Gill, E. (2019) The First Wetland Inventory Map of Newfoundland at a Spatial Resolution of 10 m Using Sentinel-1 and Sentinel-2 Data on the Google Earth Engine Cloud Computing Platform. *Remote Sens.*, 11, 43.

Mannan, B., Ray, A.K. (2003) Crisp and Fuzzy Competitive Learning Networks for Supervised Classification of Multispectral IRS Scenes. *International Journal of Remote Sensing*, 24: 3491-3502. doi: <http://dx.doi.org/10.1080/0143116021000053805>.

Mantero, P., Moser, G., Serpico, S.B. (2005) Partially supervised classification of remote sensing images through SVM-based probability density estimation. *IEEE Transactions on Geoscience and Remote Sensing* 43 (3), 559–570.

Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C., & Byers, A. H. (2011). Big data: The next frontier for innovation, competition, and productivity. *Analytics*.

Marconcini, M., Camps-Valls, G., Bruzzone, L., (2009) A composite semi supervised SVM for classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters* 6 (2), 234–238.

Margono, B.; Bwangoy, J.-R.; Potapov, P.V.; Hansen, M.C. (2014) Mapping wetlands in Indonesia using Landsat and PALSAR data-sets and derived topographical indices. *Geo-Spat. Inf. Sci.*, 17, 60–71.

Marquer, L.; Pomel, S.; Abichou, A.; Schulz, E.; Kaniewski, D.; Van Campo, E. (2008) Late Holocene high resolution palaeoclimatic reconstruction inferred from Sebkhah Mhabeul, southeast Tunisia. *Quat. Res.*, 70, 240–250.

Marr, B. (2017) What is Digital Twin Technology—And Why is It so Important? *Forbes*, 6 March.

- Martinez, J.M.; Le Toan, T. (2007) Mapping of flood dynamics and spatial distribution of vegetation in the Amazon floodplain using multitemporal SAR data. *Remote Sens. Environ.*, 108, 209–223.
- Martinis, S. (2010) Automatic Near Real-Time Flood Detection in High Resolution X-Band Synthetic Aperture Radar Satellite Data Using Context-Based Classification on Irregular Graphs. Ph.D. Thesis, LMU München: Faculty of Geosciences, Utrecht, The Netherlands, 17 December.
- Martinis, S. (2017) Improving flood mapping in arid areas using Sentinel-1 time series data. In *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Fort Worth, TX, USA, 23–28, July; pp. 193–196.
- Martinis, S.; Plank, S.; C'wik, K. (2018) The Use of Sentinel-1 Time-Series Data to Improve Flood Monitoring in Arid Areas. *Remote Sens.*, 10, 583.
- Masoud, A.; Koike, K. (2006) Arid land salinization detected by remotely sensed land cover changes: A case study in the Siwa region, NW Egypt. *J. Arid Environ.*, 66, 151–167.
- Matgen, P.; Hostache, R.; Schumann, G.; Pfister, L.; Hoffmann, L.; Savenije, H.H.G. (2011) Towards an automated SAR-based flood monitoring system: Lessons learned from two case studies. *Phys. Chem. Earth*, 36, 241–252.
- Mathur, A.; Foody, G.M. (2008) Crop classification by support vector machine with intelligently selected training data for an operational application. *Int. J. Remote Sens.*, 29, 2227–2240.
- Matthews, S. (2018) Designing Better Machines: The Evolution of the Digital Twin Explained; Keynote Delivered at Hannover Messe: Hanover, Germany.
- Mattyus, G., Wang, S., Fidler, S., and Urtasun, R. (2015) Enhancing road maps by parsing aerial images around the world. In *IEEE ICCV*.

McCord, S.E., Buenemann, M., Karl, J.W., Browning, D.M., Hadley, B.C. (2017) Integrating remotely sensed imagery and existing multiscale field data to derive rangeland indicators: application of Bayesian additive regression trees. *Rangel. Ecol. Manag.* 70, 644–655.

McFeeters, S.K. (1996) The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *Int. J. Remote Sens.*, 17, 1425–1432.

Melsheimer, C.; Tanck, G.; Gade, M.; Aplers, W. (1999) Imaging of tidal flats by multifrequency/multi-polarization synthetic aperture radar. In *Operational Remote Sensing for Sustainable Development*; Nieuwenhuis, G.J.A., Vaughan, R.A., Molenaar, M., Eds.; Balkema: Rotterdam, The Netherlands; pp. 189–192.

Mercier, G. and M. Lennon, (2003) Support vector machines for hyperspectral image classification with spectral-based kernels. in *Proc. IGARSS, Toulouse, France, July 21–25, 2003*.

Mignard, C., Nicolle, C. (2014) Merging BIM and GIS using ontologies application to Urban facility management in ACTIVE3D. *Computers in Industry*, 65(9), 1276–1290. <https://doi.org/10.1016/j.compind.2014.07.008>

Moran, M.S.; Peters-Lidard, C.D.; Watts, J.M.; McElroy, S. (2004) Estimating soil moisture at the watershed scale with satellite-based radar and land surface models. *Can. J. Remote Sens.* 2004, 30, 805–826.

Mountrakis, G., Im, J., and Ogole, C. (2011) Support vector machines in remote sensing: A review, *ISPRS J. Photogramm. Remote Sens.* 66(3), 247-259.

Mura, C., Mattausch, O. and Pajarola, R. (2016) Piecewise-planar Reconstruction of Multi-room Interiors with Arbitrary Wall Arrangements. *Computer Graphics Forum* 35(7), pp. 179–188.

Mura, C., Mattausch, O., Jaspe Villanueva, A., Gobbetti, E. and Pajarola, R., (2014). Automatic room detection and reconstruction in cluttered indoor environments with complex room layouts. *Computers & Graphics* 44, pp. 20–32.

Nagendra, H., Lucas, R., Honrado, J. P., Jongman, R. H.G, Tarantino, C., Adamo, M., Mairota, P.(2013) Remote sensing for conservation monitoring: Assessing protected areas, habitat extent, habitat condition, species diversity, and threats. *Ecological Indicators*, DOI: 10.1016/j.ecolind.2012.09.014

Nery, T., Sadler, R., Solis-Aulestia, M., White, B., Polyakov, M., Chalak, M. (2016). Comparing supervised algorithms in Land Use and Land Cover classification of a Landsat time-series. In 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS) (pp. 5165–5168). IEEE. <https://doi.org/10.1109/IGARSS.2016.7730346>.

Ngandam, M. A. H., Etouna, J., Hakdaoui, M. (2014) Contribution of the Analytic Hierarchy Process (AHP) in Decision-Making to (RE) Define Protected Areas Boundaries – Case Study in the National Park of Campo Ma'an (South-Cameroon, Central Africa). *International Journal of Science and Research (IJSR)*, Volume 3 Issue 11.

NgocSon, D., HwiRang, K., Sokanya, L. and ChangSu, S. (2018) 3D Digital Twin Models for Bridge Maintaine, 10th International Conference on Short and Medium Span Bridges Quebec City, Quebec, Canada, July 31 – August 3.

Nguemhe Fils, S.C.; Mimba, M.E.; Dzana, J.G.; Etouna, J.; Mounoumeck, P.V.; Hakdaoui, M. (2019) TM/ETM+/LDCM Images for studying land surface temperature (LST) interplay with impervious surfaces changes over time within the Douala Metropolis, Cameroon. *J. Indian Soc. Remote Sens.*, 46, 131–143.

Nguyen, A.; Le, B. (2013) 3D Point Cloud Segmentation: A Survey. In *Proceedings of the IEEE 6th International Conference on Robotics, Automation and Mechatronics (RAM 2013)*, Manila, Philippines, 12–15 November 2013.

- Ni, H.; Lin, X.; Zhang, J. (2017) Classification of ALS Point Cloud with Improved Point Cloud Segmentation and Random Forests. *Remote Sens.* 2017, 9, 288.
- Nikooheemat, S., Peter, M., Oude Elberink, S. and Vosselman, G. (2017) Exploiting Indoor Mobile Laser Scanner Trajectories for Semantic Interpretation of Point Clouds. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences IV-2/W4*(September), pp. 355–362.
- Noi, P.T.; Kappas, M. (2017) Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using sentinel-2 imagery. *Sensors*, 18, 18.
- Notti, D.; Giordan, D.; Caló, F.; Pepe, A.; Zucca, F.; Galve, J.P. (2018) Potential and Limitations of Open Satellite Data for Flood Mapping. *Remote Sens.*, 10, 1673.
- Oleire-Oltmanns, S.; Marzol, I.; Peter, K. (2012) Unmanned aerial vehicle (UAV) for monitoring soil erosion in Morocco. *Remote Sens.*, 4, 3390–3416.
- Olsen, M.J., E. Johnstone, F. Kuester, N. Driscoll, S.A. Ashford, and others, (2011). New Automated Point-Cloud Alignment for Ground-Based Light Detection and Ranging Data of Long Coastal Sections. *Journal of Surveying Engineering* Vol. 137: 14.
- Ormsby, J.P.; Blanchard, B.J.; Blanchard, A.J. (1985) Detection of lowland flooding using active microwave systems. *Photogramm. Eng. Remote Sens.* 1985, 51, 317–328.
- Owe, M.; De Jeu, R.; Walker, J. (2001) A Methodology for Surface Soil Moisture and Vegetation Optical Depth Retrieval Using the Microwave Polarization Difference Index. *IEEE Trans. Geosci. Remote Sens.*, 39, 1643–1654.
- Pal, M., and G. M. Foody. (2012) Evaluation of SVM, RVM and SMLR for Accurate Image Classification with Limited Ground Data.” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 5 (5): 1344–1355. doi:10.1109/JSTARS.2012.2215310.

Pal, N.R., Bhandari, D. (1992) On Object Background Classification. *International Journal of Systems Science*, 23: 1903-1920. doi: <http://dx.doi.org/10.1080/00207729208949429>.

Paloscia, S.; Pampaloni, P.; Santi, E. (2018) Radiometric Microwave Indices for Remote Sensing of Land Surfaces. *Remote Sens.*, 10, 1859.

Patel, N.N.; Angiuli, E.; Gamba, P.; Gaughan, A.; Lisini, G.; Stevens, F.R.; Tatem, A.J.; Trianni, G. (2015) Multitemporal settlement and population mapping from Landsat using Google Earth Engine. *Int. J. Appl. Earth Obs. Geoinf.* 2015, 35, 199–208.

Penga, J.; Biswasc, A.; Jianga, Q.; Zhaoa, R.; Hua, J.; Hua, B.; Hia, Z. (2019) Estimating soil salinity from remote sensing and terrain data in southern Xinjiang Province, China. *Geoderma*, 337, 1309–1319.

Pestunov, I., Rylov, V., Berikov, V. (2015) Hierarchical clustering algorithms for segmentation of multispectral images, *Optoelectronics Instrumentation and Data Processing* 51(4):329-338 DOI: 10.3103/S8756699015040020.

Petropoulos, G. P., Arvanitis, K., and Sigrimis, N. (2012) Hyperion hyperspectral imagery analysis combined with machine learning classifiers for land use/cover mapping, *Expert Syst. Appl.* 39(3), 3800-3809.

Pettey, C. (2017) Prepare for the Impact of Digital Twins; Gartner: Stamford, CT, USA.

Pijanowski, B.C.; Tayyebi, A.; Doucette, J.; Pekin, B.K.; Braun, D.; Plourde, J. (2014) A big data urban growth simulation at a national scale: Configuring the gis and neural network based land transformation model to run in a high performance computing (HPC) environment. *Environ. Model. Softw.*, 51, 250–268.

Pontius, R.G.; Millones, M. (2011) Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. *Int. J. Remote Sens.* 2011, 32, 4407–4429.

Pradhan, B.; Alazhari Moneir, A.A.; Ratiranjan, J. (2018) Sand dune risk assessment in Sabha region, Libya using Landsat 8, MODIS, and Google Earth Engine images. *Geomat. Nat. Hazards Risk* 2018, 9, 1280–1305.

Psomiadis, E. (2017) Flash Flood Area mapping utilising Sentinel-1 Radar Data, Earth Resources and Environmental Remote Sensing/GIS Applications VII. Proc. SPIE 2017, 10005, 100051G.

Puente, I.; González-Jorge, H.; Martínez-Sánchez, J.; Arias, P. (2013) Review of mobile mapping and surveying technologies. *Measurement* 2013, 46, 2127–2145.

Pultz, T.J.; Crevier, Y.; Brown, R.J.; Boisvert, J. (1997) Monitoring of local environmental conditions with SIR-C/XSAR. *Remote Sens. Environ.* 1997, 59, 248–255. [CrossRef]

Qi, C. R., Su, H., Mo, K., and Guibas, L. J. (2016a). PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation. *Computer Vision and Pattern Recognition*, arXiv:1612.00593.

Qi, R.; Yi, L.; Su, H.; Guibas, L.J. (2017) Pointnet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space. In *Proceedings of the Advances in Neural Information Processing Systems 30: Annual Conference on Neural Information Processing Systems*, Long Beach, CA, USA, 4–9 December 2017.

Qi, R.C.; Su, H.; Nießner, M.; Dai, A.; Yan, M.; Guibas, L.J. (2016b) Volumetric and Multi-View Cnns for Object Classification on 3d Data. In *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2016)*, Las Vegas, NV, USA, 27–30 June 2016.

Qninba, A. Ibn Tattou, M., Radi, M., El Idrissi Essougrati, A., Bensouiba, H., Ben Moussa, S. (2009) Sebkheth Imlily, une zone humide originale dans le Sud Marocain. *Bull. Inst. Sci.* 2009, 31, 51–55.

Qninba, A.; El Agbani, M.A. (2018) Maroc Sebkhath Imlili. FDR pour le Site n2323, Sebkhath Imlili, Maroc. Disponible en ligne : <https://rsis Ramsar.org/ris/2323> (accédé le 1 Octobre 2019).

Qninba, A.; El Agbani, M.A.; Radi, M.; Pariselle, A. (2012) Sur la présence de *Tilapia guineensis* (Teleostei, Cichlidae) dans les gueltas d'un affluent de l'Oued Chbeyka, l'oued Aabar (Province de Tan Tan, Sud-Ouest du Maroc). Bull. Inst. Sci. 2012, 34, 125–126.

Racoviteanu, A., Williams, M.W. (2012) Decision Tree and Texture Analysis for Mapping Debris-Covered Glaciers in the Kangchenjunga Area, Eastern Himalaya, Remote Sens., 4, 3078-3109; doi:10.3390/rs4103078

Raimondo, B. (2017). Bridge Health Monitoring Using a Machine Learning Strategy, Report # CAIT-UTC-NC3, Columbia University 640 Mudd, New York, NY 10027

Ramsey, E.; Rangoonwala, A.; Bannister, T. (2013) Coastal flood inundation monitoring with satellite C-band and L-band Synthetic Aperture Radar data. J. Am. Water Resour. Assoc. 2013, 49, 1239–1260.

Rao, G.S.; Brinda, V.; Manju Sree, P.; Bhanumurthy, V. (2006) Advantage of multi-polarized SAR data for flood extent delineation. Proc. SPIE 2006, 6410, 64100Z.

Reid, I.; Frostick, L.E. (1997) Channel form, flows and sediments in deserts. In Arid Zone Geomorphology: Process, form and Change in Drylands; Thomas, D.S.G., Ed.; John Wiley: New York, NY, USA, 1997; pp. 205–229.

Reid, I.; Powell, D.M.; Laronne, J.B.; Garcia, C. (2004) Flash floods in desert rivers: Studying the unexpected. Eos Trans. Am. Geophys. Union 2004, 75, 452.

Richards, J.A. (1993) Remote Sensing Digital Image Analysis: An Introduction; Springer: Berlin, Germany; p. 340.

Richter, B.D.; Mathews, R.; Wigington, R. (2003) Ecologically sustainable water management: Managing River flows for ecological integrity. Ecol. Appl., 13, 206–224. [CrossRef]

Rizeei, H. M., Pradhan, B. and Saharkhiz, M. A. (2018) Urban object extraction using Dempster Shafer feature-based image analysis from worldview-3 satellite imagery, international Journal of remote sensing <https://doi.org/10.1080/01431161.2018.1524173>.

Rjimati, E.C.; Michard, A.; Saddiqi, O. (2010) Anti-Atlas occidental et Provinces sahariennes. In Nouveaux Guides Géologiques et Miniers du Maroc, Volume 6. Notes et Mémoires du Service géologique du Maroc; Michard, A.

Robinson, A. C., Demšar, U., Moore, A. B., Buckley, A., Jiang, B., Field, K., Kraak, M., Silvana, P. Camboim, S. P. et Sluter, C.R. (2017) Geospatial big data and cartography: research challenges and opportunities for making maps that matter. *International Journal of Cartography*, 2017 Vol. 3, No. S1, 32–60 <https://doi.org/10.1080/23729333.2016.1278151>.

Rosen, R.; von Wichert, G.; Lo, G.; Bettenhausen, K.D. (2015) About the importance of autonomy and digital twins for the future of manufacturing. *IFAC-PapersOnLine*, 48, 567–572.

Sachdeva, S.; Bhatia, T.; Verma, A.K. (2017) Flood susceptibility mapping using GIS-based support vector machine and particle swarm optimization: A case study in Uttarakhand (India). In *Proceedings of the 2017 8th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, Delhi, India, 3–5 July; pp. 1–7.

Saddiqi, O., Chalouan, A., Mouttaqi, A., Eds.; (2011) Ministère de l’Energie et des Mines: Rabat, Morocco; Volume 561, pp. 9–95.

Salembier, P., Oliveras, A., Garrido, L. (1998) Antiextensive connected operators for image and sequence processing. *IEEE Transactions on Image Processing*, 7: 555-570. <http://dx.doi.org/10.1109/83.663500>.

Saraf, A.K. (2010) IRS-IC-LISS-III and PAN data fusion: An approach to improve remote sensing based mapping techniques. *Int. J. Remote Sens.*, 20, 1929–1934.

Schluse, M.; Atorf, L.; Rossmann, J. (2017) Experimentable Digital Twins for Model-Based Systems Engineering and Simulation-Based Development. In *Proceedings of the 2017 Annual IEEE International Systems Conference (SysCon)*, Montreal, QC, Canada, 24–27 April 2017.

Schluse, M.; Priggemeyer, M.; Atorf, L.; Rossmann, J. (2018) Experimentable Digital Twins—Streamlining Simulation-Based Systems Engineering for Industry 4.0. *IEEE Trans. Ind. Inform.*, 14, 1722–1731.

Schluse, M.; Rossman, J. (2016) From simulation to experimentable digital twins: Simulation-based development and operation of complex technical systems. In *Proceedings of the 2016 IEEE International Symposium on Systems Engineering (ISSE)*, Edinburgh, UK, 3–5 October 2016.

Schmid, T.; Koch, M.; Gumuzzio, J. (2005) Multisensor approach to determine changes of wetland characteristics in semi-arid environments (Central Spain). *IEEE Trans. Geosci. Remote Sens.*, 43, 2516–2525.

Schmidt, M.; Pringle, M.; Devadas, R.; Denham, R.; Tindall, D. A (2016) Framework for Large-Area Mapping of Past and Present Cropping Activity Using Seasonal Landsat Images and Time Series Metrics. *Remote Sens.* 2016, 8, 312.

Schnabel, A.M.; Wang, X.; Seichter, H.; Kvan, T. (2007) From virtuality to reality and back. *Conference on International Association of Societies of design Reserch (IASDR)* p1-15.

Schott, J.R.; Salvaggio, C.; Volchok W.J. (2008) Radiometric scene normalization using pseudo invariant features. *Remote Sens. Environ.*, 26, 1–16.

Schumann, G.; Matgen, P.; Hoffmann, L.; Hostache, R.; Pappenberger, F.; Pfister, L. (2007) Deriving distributed roughness values from satellite radar data for flood inundation modellin. *J. Hydrol.* 2007, 344, 96–111.

Serrano, W. (2018) Digital Systems in Smart City and Infrastructure: Digital as a Service Smart Cities, 1, 134–153; doi:10.3390/smartcities1010008.

Shafizadeh-Moghadam, H.; Valavi, R.; Shahabi, H.; Chapi, K.; Shirzadi, A. (2018) Novel forecasting approaches using combination of machine learning and statistical models for flood susceptibility mapping. *J. Environ. Manag.* 2018, 217, 1–11.

Shaikh, M. Z.; DishantShah ;Kawale, V.; Anand K. (2017)- Developing Smart Cities in a BIM environment. IOSR Journal of Mechanical and Civil Engineering (IOSR-JMCE) e-ISSN: 2278-1684,p-ISSN: 2320-334X, Volume 14, Issue 5 Ver. V (Sep. - Oct. 2017), PP 11-16. www.iosrjournals.org.

Shalaby, A. et Tateishi, R. (2007) Remote sensing and GIS for mapping and monitoring land cover and land-use changes in the Northwestern coastal zone of Egypt. Applied Geography, 27(1), 28–41. <https://doi.org/10.1016/J.APGEOG.2006.09.004>.

Shang, X., (2013) Evaluating the capability of machine-learning algorithms and object-oriented classification techniques using hyperspectral remote sensing for the discrimination of Australian native forest species in south-eastern Australia, PhD. Thesis, School of Earth and Environmental Sciences, University of Wollongong.

Shao, Y.; Lunetta, R.S. (2012) Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points. ISPRS J. Photogramm. Remote Sens. 2012, 70, 78–87.

Sharratt, B.; Feng, G.; Wendling, L. (2007) Loss of soil and PM10 from agricultural fields associated with high winds on the Columbia Plateau. Earth Surf. Proc. Land 2007, 32, 621–630.

Sherrah, J. (2016). Fully convolutional networks for dense semantic labelling of high-resolution aerial imagery. arXiv. [Online]. Available: <https://arxiv.org/abs/1606.02585>.

Shi, D.; Yang, X. (2016) An assessment of algorithmic parameters affecting image classification accuracy by random forests. Photogramm. Eng. Remote Sens., 82, 407–417.

Shi, P., Cui, Y., Xu, K., Zhang, M. and Ding, L. (2019) Data Consistency Theory and Case Study for Scientific Big Data, Information, 10, 137; doi:10.3390/info10040137.

Shim, C.S, Dang, N.S, Kang, H.R, and Kim, DC. (2016) 3D Information Model Based Bridge maintenance. Proceedings of the 5th International Technical Conference, Kota Kinabalu, Malaysia, Nov., 449-455.

Shim, C.S, Kang, H.R, Dang, N.S, and Lee, D.K. (2017) Development of BIM-based bridge maintenance system for cable-stayed bridges. *Smart Structures Systems*, 20(6): 697-708.

Shim, C.S, Kim, S.W, Song, H.H, and Yun, N.R. (2011) Development of BIM for a Maintenance System of Subway Infrastructure. *Journal of KIBIM*, 1(1): 6-12.

Shim, C.S., Kang HR and Dang NS. (2019) Digital Twin Models for Maintenance of cadre-supported Bridges. *International Conference on Smart Infrastructure and Construction 2019 (ICSIC)*.

Shim, H.M.; Lee, S. (2015) Multi-channel electromyography pattern classification using deep belief networks for enhanced user experience. *J. Central South Univ.*, 22, 1801–1808.

Siddiqui, Y. (2003) The modified IHS method for fusing satellite imagery. In *Proceedings of the ASPRS 2003 Annual Conference Proceedings*, Anchorage, AK, USA, 5–9 May.

Simonetto, A., (2018) Time-Varying Optimization: Algorithms and Engineering Applications. *23rd International Symposium on Mathematical Programming (ISMP)*.

Sindikubwabo, C.; Li, R.; Wang, C. (2018) Abrupt Change in Sahara Precipitation and the Associated Circulation Patterns. *Atmospheric and Climate Sciences*, 8, 262-273.

Singh, A., (1989) Digital Change Detection Techniques Using Remotely-Sensed Data. *Int. J. Rem. Sens.* 10 (6), 989–1003.

Song, M. M., Li, Z., Zhou, B., and Li, C.L., (2014) Cloud computing model for big geological data processing,” *Applied Mechanics and Materials*, vol. 475-476, pp. 306–311.

Srivastava, P. K., Han, D., Rico-Ramirez, M. A., Bray, M., Islam, T. (2012). Selection of classification techniques for land use/land cover change investigation. *Advances in Space Research*, 50(9), 1250–1265. <https://doi.org/10.1016/J.ASR.2012.06.032>.

Stantic, B., & Pokorný, J. (2014). Opportunities in big data management and processing. *Frontiers in Artificial Intelligence & Applications*, 270, 15–26. doi:10.3233/978-1-61499-458-9-15.

Szuster, B.W.; Chen, Q.; Borger, M. A (2011) comparison of classification techniques to support land cover and land use analysis in tropical coastal zones. *Appl. Geogr.*, 31, 525–532.

Talari, S.; Shafie-Khah, M.; Siano, P.; Loia, V.; Tommasetti, A.; Catalão, J. (2017) A review of smart cities based on the internet of things concept. *Energies*, 10, 421.

Tang, Y., Jing, L., Shi F., Li, X., Qiu, F. (2019) A Hybrid Model Integrating Spatial Pattern, Spatial Correlation, and Edge Information for Image Classification, *Remote Sens.*, 11, 1599; doi:10.3390/rs11131599.

Tanner, S.; Katra, I.; Haim, A.; Zaady, E. (2016) Short-term soil loss by eolian erosion in response to different rainfed agricultural practices. *Soil Tillage Res.*, 155, 149–156. [CrossRef]

Tayyebi, A. and Pijanowski, B. C. (2014) Comparing three global parametric and local non-parametric models to simulate land use change in diverse areas of the world. *Environ. Model. Software* 59, 202–221.

Tehrany, M. S., Jones, S., & Shabani, F. (2019). Identifying the essential flood conditioning factors for flood prone area mapping using machine learning techniques. *Catena*, 175(April 2018), 174–192. <https://doi.org/10.1016/j.catena.2018.12.011>.

Tehrany, M.S.; Pradhan, B.; Jebur, M.N. (2014) Flood susceptibility mapping using a novel ensemble weights-of-evidence and support vector machine models in GIS. *J. Hydrol.*, 512, 332–343.

Teillet, P.M. (1992) An Algorithm for the Radiometric and Atmospheric Correction of AVHRR Data in the Solar Reflective Channels. *Remote Sens. Environ.* 1992, 41, 185–195.

Teluguntla, P.; Thenkabail, P.S.; Oliphant, A.; Xiong, J.; Gumma, M.K.; Congalton, R.G.; Yadav, K.; Huete, A. (2018) A 30-m landsat-derived cropland extent product of Australia and China using random forest machine learning algorithm on Google Earth Engine cloud computing platform. *ISPRS J. Photogramm. Remote Sens.*, 144, 325–340.

Tharwat, A. (2019) Parameter Investigation of Support Vector Machine Classifier with Kernel Functions. *Knowl. Inf. Syst.* 2019, 3, 1–34.

Thunig, H., Wolf, N., Naumann, S., Siegmund, A., Jurgens, C., Uysal, C., & Maktav, D. (2011). Land use/land cover classification for applied urban planning - the challenge of automation. In 2011 Joint Urban Remote Sensing Event (pp. 229–232). IEEE. <https://doi.org/10.1109/JURSE.2011.5764762>

Tian, J. and Dezert, J. (2018) - Fusion of multispectral imagery and DSMs for building change detection using belief functions and reliabilities. *Int. J. Image Data Fusion*.

Tian, S.; Zhang, X.; Tian, J.; Sun, Q.R. (2016) Random forest classification of wetland landcovers from multi-sensor data in the arid region of Xinjiang, China. *Remote Sens.*, 8, 954.

Tipping, M. E. (2004). Bayesian Inference: An Introduction to Principles and Practice in Machine Learning. In *Advanced lectures on machine Learning* (pp. 41–62). Berlin, Heidelberg: Springer. Retrieved from <http://www.miketipping.com/papers.htm>.

Topouzelis, K., Psyllos, A., (2012) Oil spill feature selection and classification using decision tree forest on SAR image data. *ISPRS J. Photogramm. Remote Sens.* 68, 135–143.

Torres-Sánchez, J., Peña, J., De Castro, A., López-Granados, F., (2014) Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Comput. Electron. Agric.* 103, 104–113.

Touzi, R.; Boerner, W.; Lee, J.S.; Luneberg, E. (2004a) A review of polarimetry in the context of synthetic aperture radar: Concepts and information extraction. *Can. J. Remote Sens.* 2004, 30, 380–407.

- Touzi, R.; Charbonneau, F. (2002) Characterization of target symmetric scattering using polarimetric SARs. *IEEE Trans. Geosci. Remote Sens.*, 40, 2507–2516.
- Touzi, R.; Hélie, R.; Filfil, R. (2005) On the use of polarimetric SAR information for extraction of wetland indicators. In *Proceedings of the IGARSS'05, Seoul, Korea, 25–29 July 2005*.
- Touzi, R.; Raney, R.K.; Charbonneau, F. (2004b) On the use of permanent symmetric scatterers for ship characterization. *IEEE Trans. Geosci. Remote Sens.*, 42, 2039–2045.
- Toyra, J.; Pietroniro, A. (2005) Towards operational monitoring of a northern wetland using geomatics-based techniques. *Remote Sens. Environ.* 2005, 97, 174–191.
- Trape, S. (2009) Impact of climate change on the relict tropical fish fauna of Central Sahara: Threat for the survival of Adrar mountains fishes, Mauritania. *PLoS ONE* 2009, 4, e4400.
- Trape, S. (2016) A new cichlid fish in the Sahara: The Ounianga Serir lakes (Chad), a biodiversity hotspot in the desert. *C. R. Biol.*, 339, 529–536.
- Troya-Galvis, A., Gançarski, P., Berti-Équille, L. (2016) Collaborative Segmentation and Classification for remote sensing image analysis, *Conference at Cancun, Mexico Volume: The 23rd International Conference on Pattern Recognition (ICPR2016)*.
- Tsay, C.; Pattison, R.C.; Piana, M.R.; Baldea, M. (2018) A survey of optimal process design capabilities and practices in the chemical and petrochemical industries. *Comput. Chem. Eng.*, 112, 180–189. [Google Scholar].
- Tso, B., Mather, P. M. (2009) *Classification Methods for Remotely Sensed Data (Second)*. Boca Raton: CRC Press.
- Van Beijma, S.; Comber, A.; Lamb, A. (2014) Random forest classification of salt marsh vegetation habitats using quad-polarimetric airborne SAR, elevation and optical RS data. *Remote Sens. Environ.* 2014, 149, 118–129.

- Van der Linden, S., Janz, A., Waske, B., Eiden, M., and Hostert, P., (2007) Classifying segmented hyperspectral data from a heterogeneous urban environment using support vector machines, *J. Appl. Remote Sens.* 1(1), 013543-013543-013517.
- Vermeesch, P. and Garzanti, E. (2015) Making geological sense of ‘big data’ in sedimentary provenance analysis. *Chemical Geology*, vol. 409, pp. 20–27.
- Verstraete, M.M.; Pinty, B. (1996) Designing optimal spectral indexes for remote sensing applications. *Remote Sens. Environ.*, 3434, 1254–1265.
- Vilches, J.P. (2013) Detection of Areas Affected by Flooding River using SAR images. In Seminar: Master in Space Applications for Emergency Early Warning and Response; National University of Cordoba: Córdoba, Argentina; p. 40.
- Voigt, S.; Martinis, S.; Zwenzner, H.; Hahmann, T.; Twele, A.; Schneiderhan, T. (2008) Extraction of flood masks using satellite based very high-resolution SAR data for flood management and modeling. In *Proceedings of the 4th International Symposium on Flood Defense Managing Flood Risk Reliability and Vulnerability*, Toronto, ON, Canada, 6–8 May 2008; pp. 1–8.
- Volk, R, Stengel, J, and Schultmann, F. 2014. Building Information Modeling (BIM) for existing buildings - Literature review and future needs. *Automation in Construction*, 38: pp. 109–127.
- Vosselman, G. (2000) Slope Based Filtering of Laser Altimetry Data. *Int. Arch. Photogramm. Remote Sens.* 2000, 33, 935–942.
- Wang Q., Guo J. et Kim M.K (2019) - An Application Oriented Scan-to-BIM Framework. *Remote Sens.* 2019, 11, 365; doi:10.3390/rs11030365.
- Wang, L.; Qu, J.J. (2007) NMDI: A Normalized Multi-Band Drought Index for Monitoring Soil and Vegetation Moisture with Satellite Remote Sensing. *Geophys. Res. Lett.*, 34, 1–5.

- Wang, R.; Peethambaran, J.; Chen, D. (2018) LiDAR point clouds to 3-D urban models: a review. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 2018, 11, 606–627.
- Wang, X.; Xiao, X.; Zou, Z.; Chen, B.; Ma, J.; Dong, J.; Doughty, R.B.; Zhong, Q.; Qin, Y.; Shengqi Dai, S. (2018) Tracking annual changes of coastal tidal flats in China during 1986–2016 through analyses of Landsat images with Google Earth Engine. *Remote Sens. Environ.* 2018, in press.
- Wang, Y. (2004) Using Landsat 7 TM data acquired days after a flood event to delineate the maximum flood extent on a coastal floodplain. *Int. J. Remote Sens.*, 25, 959–974. [CrossRef]
- Warner, T.T. (2004) *Desert Meteorology*; Cambridge University Press: Edinburgh, Scotland, UK, 2004; p. 612.
- Waske, B., Benediktsson, J.A., (2007). Fusion of support vector machines for classification of multisensor data. *IEEE Transactions on Geoscience and Remote Sensing* 45 (12), 3858–3866.
- Weinmann, M., Jutzi, B., Hinz, S., and Mallet, C. (2015a). Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105.
- Weinmann, M., Schmidt, A., Mallet, C., Hinz, S., Rottensteiner, F., and Jutzi, B. (2015b). Contextual Classification of Point Cloud Data By Exploiting Individual 3D Neighbourhoods. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3/W4:271–278.
- West, T.D.; Pyster, A. (2015) Untangling the Digital Thread: The Challenge and Promise of Model-Based Engineering in Defense Acquisition. *Insight* 2015, 18, 45–55.
- Wilson, B.T.; Lister, A.J.; Riemann, R.I. (2012) A nearest-neighbor imputation approach to mapping tree species over large areas using forest inventory plots and moderate resolution raster data. *For. Ecol. Manag.*, 271, 182–198.

- Xiang, F., Feng, Z., Lin, Z., Lin, X. (2017) Hyperspectral Image Segmentation with Markov Random Fields and a Convolutional Neural Network, *EEE Transactions on Image Processing* PP(99) DOI: 10.1109/TIP.2018.2799324.
- Xie, Y., Wang, M., Liu, X., & Wu, Y. (2017) Integration of GIS and Moving Objects in Surveillance Video. *ISPRS International Journal of Geo-Information*, 6(4), 94.
<https://doi.org/10.3390/ijgi6040094>
- Xiong, L.; Deng, R.; Li, J.; Liu, X.; Qin, Y.; Liang, Y.; Liu, Y. (2018) Subpixel Surface Water Extraction (SSWE) Using Landsat 8 OLI Data. *Water*, 10, 653.
- Xiua, L.; Yana, C.; Lic, X.; Qiand, D.; Fenga, K. (2019) Changes in wetlands and surrounding land cover in a desert area under the influences of human and climatic factors: A case study of the Hongjian Nur region. *Ecol. Indic.*, 101, 261–273.
- Xu, H. (2006) Modification of normalized difference water index (NDWI) to enhance open water features in remotely sensed imagery. *Int. J. Remote Sens.* 2006, 27, 3025–3033.
- Yamamura, S., Fan, L., & Suzuki, Y. (2017). Assessment of Urban Energy Performance through Integration of BIM and GIS for Smart City Planning. *Procedia Engineering*, 180, 1462– 1472. <https://doi.org/10.1016/j.proeng.2017.04.309>
- Yan, Z.; Petit-Maire, N. (1994) The last 140 ka in the Afro-Asian arid/semi-arid transitional zone. *Palaeogeogr. Palaeoclimatol. Palaeoecol.*, 110, 217–233.
- Yang, C.; Yu, M.; Hu, F.; Jiang, Y.; Li, Y. (2017b) Utilizing cloud computing to address big geospatial data challenges. *Comput. Environ. Urban Syst.*, 61, 120–128.
- Ye, C., Butler, L., Calka, B., Iangurazov, M., Lu, Q., Gregory, A., Girolami, M., Middleton, M. (2019) A Digital Twin of Bridges for Structural Health Monitoring for Proceedings of the 12th International Workshop on Structural Health Monitoring.

Youssef, A.M.; Pradhan, B.; Sefry, S.A. (2016) Flash flood susceptibility assessment in Jeddah city Kingdom of Saudi Arabia) using bivariate and multivariate statistical models. *Environ. Earth Sci.*, 75, 12.

Zeigler, B.; Muzy, A.; Kofman, E. (2018) *Theory of Modeling and Simulation: Discrete Event and Iterative System Computational Foundations*, 3rd ed.; Academic Press: New York, NY, USA, 2018.

Zeng, Y.; Xiang, N.; Feng, Z.; Hu, H. (2006) Albedo-NDVI space and remote sensing synthesis index models for desertification monitoring. *Sci. Geogr. Sin.*, 26, 75–81.

Zerhouny, M., Hakdaoui, M., Fadil, Abdelhamid (2016) Combined Approaches for the Automatic Detection of Urban Areas: Application to the study of urban sprawl of Casablanca. *International Journal of Advanced Research*. 4, 30-43, doi: 10.21474/IJAR01/1455

Zerhouny, M.; Fadil, A.; Hakdaoui, M. (2018) Underground Space Utilization in the Urban Land-Use Planning of Casablanca (Morocco). *Land*. 7, 143.

Zhang J., Okin G., Zhou B. (2019) Assimilating optical satellite remote sensing images and field data to predict surface indicators in the Western U.S.: Assessing error in satellite predictions based on large geographical datasets with the use of machine learning, *Remote Sensing of Environment* 233 111382.

Zhang P., Gong M., Su L., Liu J., and Li Z., (2016) “Change detection based on deep feature representation and mapping transformation for multi-spatial-resolution remote sensing images,” *ISPRS J. Photogrammetry Remote Sens.*, vol. 116, pp. 24–41, June 2016.

Zhang, L.; Zhang, L.; Du, B. (2016) Deep Learning for remote sensing data: A technical tutorial on the state of the art. *IEEE Geosci. Remote Sens. Mag.* 2016, 4, 22–40.

Zhou, J.; Civco, D.L.; Silander, J.A. (1998) A wavelet transform method to merge Landsat TM and SPOT panchromatic data. *Int. J. Remote Sens.*, 19, 743–757.

Zhou, L., Pan, S., Wang, J., & Vasilakos, A. V. (2017). Machine learning on big data: Opportunities and challenges. *Neurocomputing*, 237 (December 2016), 350–361. <https://doi.org/10.1016/j.neucom.2017.01.026>.

Zhu, J., Wright, G., Wang, J., & Wang, X. (2018) A Critical Review of the Integration of Geographic Information System and Building Information Modelling at the Data Level. *ISPRS International Journal of Geo-Information*, 7(2), 66. <https://doi.org/10.3390/ijgi7020066>.

Zhu, Y., Tan, Y., Li, R., and Luo, X., (2016) Cyber-Physical-Social- Thinking modeling and computing for geological information service system,” *International Journal of Distributed Sensor Networks*, vol. 12, no. 11.

Zlatanova, S., Rahman, A.A. et Pilouk, M. (2002) Trends in 3D GIS development. In: *Journal of Geospatial Engineering*, vol.4, n.2, pp.1-10.

Zoka, M.; Psomiadis, E.; Dercas, N. (2018) The Complementary Use of Optical and SAR Data in Monitoring Flood Events and Their Effects. *Multidiscip. Digit. Publ. Inst. Proc*, 2, 644.

Zongyi, M.; Yaowen, X.; Jizong, J.; Linlin, L.; Xiangqian, W. (2011) The Construction and Application of an Albedo-NDVI Based Desertification Monitoring Model. *Procedia Environ. Sci.* 2011, 10, 2029–2035.