



Centre des Etudes Doctorales : Sciences et Techniques et Sciences Médicales
Formation Doctorale : Sciences de l'Ingénieur, Sciences Physiques, Mathématiques et Informatique
Discipline : Informatique
Spécialité : Informatique
Laboratoire : Systèmes Intelligents et Applications

Thèse pour l'obtention de DOCTORAT

Application du Deep Learning pour la détection de changements en imagerie RADAR

Préparée par : Sanae ATTIOUI

Soutenue le 15 juillet 2023 devant le jury :

Nom et Prénom	Grade	Etablissement	Qualité
Arsalane ZARGHILI	PES	Faculté des Sciences et Techniques de Fès	Président
Mostafa EZZIYYANI	PES	Faculté des Sciences et Techniques de Tanger	Rapporteur & examinateur
Brahim AKSASSE	PES	Faculté des Sciences Meknès	Rapporteur & examinateur
Khalid ZENKOUAR	PES	Faculté des Sciences et Techniques de Fès	Rapporteur & examinateur
Khalid ABBAD	PH	Faculté des Sciences et Techniques de Fès	Examinateur
Saïd NAJAH	PES	Faculté des Sciences et Techniques de Fès	Directeur de thèse

Remerciements

La présente thèse est l'aboutissement de quelques années de persévérances, de dévouement et de sacrifices. Divers intervenants ont joué un rôle important dans sa mise en œuvre. Les orateurs suivants tiennent une place particulière dans mon cœur et méritent mon respect et ma profonde reconnaissance.

Avant tout, j'aimerais exprimer ma profonde gratitude à mon directeur de thèse, mon encadrant Professeur **Saïd NAJAH**. Sans son mentorat continu, ses conseils judicieux, ses suggestions pertinentes et sa motivation cette thèse n'aurait jamais abouti.

En outre, ma gratitude va aussi à l'ensemble des rapporteurs et membres de jury, messieurs **Arsalane ZARGHILI**, **Mostafa EZZIYYANI**, **Brahim AKSASSE**, **Khalid ZENKOUAR** et **Khalid ABBAD** pour le temps qu'ils ont consacré à l'évaluation et à l'examen de ce travail.

Par ailleurs, je tiens également à remercier tous les professeurs du **laboratoire Systèmes Intelligents et Applications** pour l'accueil chaleureux. Un merci particulier au Pr. **Khalid ZENKOUAR**, directeur du Laboratoire et au Pr. **Fatiha MRABTI** pour leurs précieux conseils et encouragements.

Je ne peux oublier tous ceux qui m'ont soutenu et encouragé au cours des moments difficiles, ma dévotion sincère à tous ceux qui ont contribué de près ou de loin à ce travail et à sa réussite.

Mes pensées vont aussi vers **Mes parents** pour leur soutien inconditionnel aux décisions prises qui ont abouti à mon Moi actuel. **A ma sœur et mes frères** pour leur soutien moral tout au long de la rédaction de cette thèse. Cette réalisation n'aurait pas été possible sans eux. Merci.

Le dernier mot va à ma petite fille **Yasmina**, la lumière de ma vie et qui me donne la force ainsi que la motivation supplémentaire pour aller de l'avant. Cette thèse lui est dédiée.

Résumé

L'étalement urbain et les dommages accrus provoqués par les catastrophes naturelles (tremblements de terre, inondations, incendies de forêt, etc.) ont contribué à souligner l'importance croissante de la technique de détection de changements à l'aide des images de télédétection.

Le radar à synthèse d'ouverture (SAR) a présenté une excellente alternative à la télédétection terrestre, avec des applications allant de l'exploration spatiale à la détection de changements. Au cours des dernières décennies, ces techniques de détection en imagerie SAR ont beaucoup évolué, parallèlement aux progrès de l'intelligence artificielle, contribuant au développement d'études dans des endroits difficiles d'accès.

L'apprentissage en profondeur a pris son envol dans ces applications. Il est de plus en plus le modèle de choix, en ce sens qu'il a ouvert de nouvelles perspectives pour la surveillance et l'évaluation de l'environnement. Cela a permis de réduire la forte dépendance au travail manuel et offrir une nouvelle méthode de traitement automatique et perspicace pour répondre aux exigences actuelles.

Des algorithmes de détection de changements basés sur des cadres d'apprentissage en profondeur ont atteint d'excellentes performances et ont permis de détecter des changements plus délicats. À ce jour, leur efficacité et leur précision avec une présence de bruits de speckle et de données d'entraînement étiquetées limitées sont toujours pleines de défis.

Dans ce contexte, la visée essentielle de ce travail a consisté à apporter plus d'efficacité et de faisabilité aux modèles de détection de changements actuels, en améliorant leurs performances et leurs précisions sans introduire de calculs additionnels, tout en réduisant leur complexité, cela a été réalisé grâce à l'introduction de l'apprentissage profond.

L'efficacité et la fiabilité des méthodes proposées ont été démontrées en comparant ses résultats avec d'autres méthodes de pointe.

Mots clés : images de télédétection, radar à synthèse d'ouverture, détection de changements, intelligence artificielle, apprentissage en profondeur.

Abstract

Urban sprawl and the increased damage caused by natural disasters (earthquake, flood, forest fires, etc.) have contributed to the growing significance of remote-sensing image change detection technology.

Synthetic Aperture Radar (SAR) has made an excellent alternative to terrestrial remote sensing, with applications ranging from space exploration to change detection.

Over the past few decades, these detection techniques in SAR imagery have evolved significantly, alongside advances in artificial intelligence, contributing to the development of studies in hard-to-reach locations.

Deep learning has taken off in these applications, it is increasingly the model of choice, it has opened up new perspectives for environmental monitoring and assessment, which can reduce the heavy reliance on manual work and provide a new automatic and insightful processing method to meet current requirements.

Change detection algorithms based on deep learning frameworks achieved excellent performance and detected more delicate changes. To date, their efficiency and accuracy with a presence of speckle noise and limited labeled training data are still full of challenges.

In this context, the main goal of this work consisted in bringing more efficiency and feasibility to current change detection models, by improving their performance and accuracy without introducing additional computations, while reducing their complexity, this was achieved through the introducing of deep learning.

The effectiveness and reliability of the proposed methods are demonstrated by comparing its results with other state-of-the-art methods.

Key words: remote sensing images, synthetic aperture radar, change detection, artificial intelligence, deep learning.

Liste des figures

Figure 1.1: Géométrie d'une acquisition SAR	19
Figure 1.2: Résolution spatiale des images SAR	21
Figure 1. 3: Géométrie d'imagerie SAR- Le point de diffusion est visible par l'antenne à partir de divers emplacements (Figure extraite de [20]).....	24
Figure 1.4: Image RGB dans la base de Pauli. $ S_{HH} + S_{VV} ^2$, $ S_{HH} - S_{VV} ^2$, $ S_{HV} ^2$	30
Figure 1. 5: Plan H - α	33
Figure 1. 6: Distorsion géométrique en imagerie SAR (https://earth.esa.int/handbooks/asar/CNTR1-1-2.html).....	35
Figure 2. 1: Processus général de la détection de changements en imagerie SAR.....	39
Figure 2. 2: Ensemble de données de Wuhan : (a) image acquise le 14 octobre 2015 ;	40
Figure 2. 3: Cadre général de la détection de changements par comparaison post-classification.....	44
Figure 2. 4: Cadre général de la détection de changements par analyse post-comparaison.....	44
Figure 3. 1: Architecture de la Machine de Boltzmann restreintes RBM	60
Figure 3. 2: Visualisation de la manière dont Gibbs procède à l'échantillonnage par couche dans RBM.....	62
Figure 3. 3: Architecture de Réseaux de croyances profondes (3 unités cachées).....	64
Figure 3. 4: Organigramme de la méthode proposée	65
Figure 3. 5: Organigramme de l'algorithme JFRFCM	67
Figure 3. 6: Processus de génération de caractéristiques de voisinage	68
Figure 3. 7: Images multitemporelles relatives à l'estuaire du fleuve Jaune.	69
Figure 3. 8: Les terres agricoles de l'estuaire du fleuve Jaune	70
Figure 3. 9: Le jeu de données du Fleuve Jaune	70
Figure 3. 10: Ensemble de données de Berne	70
Figure 3. 11: Influence de la taille du quartier dans l'extraction des caractéristiques	72
Figure 3. 12: Résultats de la détection de changements obtenus par différentes méthodes sur l'ensemble de données des terres agricoles de l'estuaire du Fleuve Jaune.....	73
Figure 3. 13: Résultats de la détection de changement obtenus par différentes méthodes sur l'ensemble du Fleuve Jaune.....	74
Figure 3. 14: Résultats de la détection de changement obtenus par différentes méthodes sur l'ensemble de données de Berne	74

Figure 4. 1: Module d'attention à blocs convolutifs	86
Figure 4. 2: Organigramme de la méthode de détection de changements proposée	88
Figure 4. 3: Organigramme illustrant la méthode de détection de changements proposée basée sur Mdp-CapsNet	90
Figure 4. 4: Relation entre la taille du patch (k) et le critère d'évaluation PCC	96
Figure 4. 5: Résultats visualisés de diverses méthodes de détection de changements sur quatre ensembles de données.	100
Figure 5. 1: La méthode de détection de changements proposée	110
Figure 5. 2: Module d'extraction de caractéristiques multi-échelles	110
Figure 5. 3: Images Los Angeles Pauli-RVB.	111
Figure 5. 4: Résultats visualisés sur l'Image Los Angeles.	111

Liste des tableaux

Tableau 2. 1: Illustration des ensembles de données SAR.....	40
Tableau 3. 1: Détails des ensembles de données.....	70
Tableau 3. 2: Effet des échantillons virtuels sur les résultats de la détection de changements	72
Tableau 3. 3: Résultats de la détection de changements sur l'ensemble de données des terres agricoles de l'estuaire du Fleuve Jaune	73
Tableau 3. 4: Résultats de la détection de changements sur l'ensemble de données du fleuve Jaune.....	75
Tableau 3. 5: Résultats de la détection de changements sur l'ensemble de données Bern Data.....	75
Tableau 3. 6: Comparaison du temps de fonctionnement	75
Tableau 4.1: Relation entre le nombre d'échantillon de formation et le critère d'évaluation PCC sur l'ensemble de données Yellow River A.....	96
Tableau 4. 2: Influence du modèle d'attention et de la fonction de perte	97
Tableau 4. 3: Résultats de la détection de changements sur l'ensemble de données Yellow River..	98
Tableau 4. 4: Résultats de la détection de changements sur l'ensemble de données Coastline et San Francisco	99
Tableau 5. 1: Résultats de la détection de changements sur le jeu de donnée Los Angeles	112

Liste des abréviations

RADAR	: RADIO Detection And Ranging
RSO	: Radar à Synthèse d'Ouverture
SAR	: Synthetic Aperture Radar
SLAR	: Side Looking Aperture Radar
PolSAR	: Radar à synthèse d'ouverture polarimétrique
DL	: Apprentissage en profondeur (Deep learning)
DI	: Image de différence
FCM	: C-moyens flous (Fuzzy C-Means)
LR	: Opérateur de rapport logarithmique
MR	: Opérateur de rapport moyen
NR	: Opérateur de rapport basé sur le voisinage
ML	: Apprentissage automatique (machine learning)
CNN	: Réseau neuronal convolutif
DBN	: Réseau de croyances profondes (Deep Belief Networks)
RBN	: Réseaux de Croyances Profondes
SAEs	: Auto-encodeurs empilés
RNN	: Réseau neuronal récurrent multicouche siamois profond
RBM	: Machines de Boltzmann restreintes
SVM	: Machine à vecteurs de support (SVM)
FRFCM	: C-moyens flous Rapide et Robuste (Fast and robust fuzzy C-means)
RM	: Reconstruction morphologique (RM)
OE	: Erreurs globales
PCC	: Classification correcte en pourcentage
Kappa	: Coefficient Kappa
CapsNet	: Réseau neuronal à capsules
Mdp-CapsNet	: Réseau neuronal à capsules parallèles multidimensionnelles

Table des matières

INTRODUCTION GENERALE.....	10
CONTEXTE ET MOTIVATIONS.....	10
PROBLEMATIQUES ET OBJECTIFS	11
CONTRIBUTIONS ET PERSPECTIVES.....	12
STRUCTURE DE LA THESE	15
CHAPITRE 1 : L’IMAGERIE SAR/POLSAR : ATOUTS ET RESTRICTIONS POUR L'OBSERVATION TERRESTRE	17
1.1 INTRODUCTION	17
1.2 RADAR A SYNTHESE D’OUVERTURE (RSO/SAR).....	19
1.2.1 Géométrie d’acquisition des images SAR.....	19
1.2.2 Résolution spatiale des images SAR.....	21
1.3 IMAGERIE SAR POLARIMETRIQUE.....	24
1.3.1 Les représentations polarimétriques.....	25
1.3.2 Représentations matricielles.....	27
1.3.3 Décompositions polarimétriques.....	28
1.4 CARACTERISTIQUES DE L'IMAGERIE SAR : ATOUTS ET RESTRICTIONS.....	33
1.4.1 Distorsion géométrique	34
1.4.2 Interaction entre le signal Radar et le milieu.....	35
1.4.3 Propriétés bruit de chatoiement (speckle)	36
1.5 CONCLUSION.....	37
CHAPITRE 2 : REVUE BIBLIOGRAPHIQUE DES ALGORITHMES DE DETECTION DE CHANGEMENTS EN IMAGERIE SAR	38
2.1 INTRODUCTION	38
2.2 PROCESSUS DE DETECTION DE CHANGEMENTS EN IMAGERIE SAR.....	39
2.2.1 Ensemble de données (Dataset).....	40
2.2.2 Prétraitement	41
2.2.3 Techniques de détection de changements	42
2.2.4 Évaluation des performances	45
2.3 DETECTION DE CHANGEMENTS EN IMAGERIE SAR POST-COMPARAISON : TRAVAUX CONNEXES.....	45
2.3.1 Génération de l’image de différence (DI)	46
2.3.2 Analyse de l’image de différence (DI).....	47
2.4 CONCLUSION.....	51
CHAPITRE 3 : METHODE DE DETECTION DE CHANGEMENTS BASEE SUR UN RESEAU DE CROYANCE PROFOND.....	52
3.1 INTRODUCTION	52
3.2 PRELIMINAIRES METHODOLOGIQUES	57
3.2.1 Algorithme FRFCM (C-moyens flous Rapide et Robuste).....	57
3.2.2 Les réseaux de neurones profonds	60

3.2.3 Échantillon virtuel	64
3.3 METHODOLOGIE PROPOSEE	65
3.3.1 Pré-classification FR Fuzzy C-Means Clustering	66
3.3.2 Génération des échantillons	67
3.3.3 Classification à l'aide d'un réseau de croyances profondes	67
3.4 RESULTATS EXPERIMENTAUX ET ANALYSE	68
3.4.1 Configuration expérimentale	68
3.4.2 Résultats expérimentaux	71
3.4.3 Analyse des résultats	72
3.4.4 Comparaison du temps de fonctionnement	75
3.5 CONCLUSIONS	75
CHAPITRE 4 : METHODE DE DETECTION DE CHANGEMENTS BASEE SUR UN RESEAU NEURONAL A CAPSULES	77
4.1 INTRODUCTION	77
4.2 PRELIMINAIRES ET METHODE DE DETECTION DE CHANGEMENTS PROPOSEE	84
4.2.1 FLICM pour la détection de changements	84
4.2.2 Mécanisme d'attention	85
4.2.3 Méthodologie proposée pour la détection de changements SAR.....	87
4.2.4 Pré-classification	88
4.3 RESULTATS ET DISCUSSION	93
4.3.1 Description de l'ensemble de données et critères d'évaluation	94
4.3.2 Analyse des paramètres	95
4.3.3 Comparaison des performances de l'approche proposée avec d'autres algorithmes de détection de changements	98
4.4 CONCLUSION.....	100
CHAPITRE 5 : DETECTION DE CHANGEMENTS EN IMAGERIE POLSAR ..	102
5.1 INTRODUCTION	102
5.2 DETECTION DE CHANGEMENTS EN IMAGERIE POLSAR	104
5.2.1 Travaux connexes.....	104
5.2.2 Formulation du problème	107
5.3 CONCLUSION.....	112
CONCLUSION GENERALE ET RECHERCHES FUTURES.....	113
SYNTHESE ET CONCLUSION	113
RECOMMANDATIONS ET TRAVAUX FUTURES.....	114
BIBLIOGRAPHIE	116

Introduction générale

Contexte et motivations

Les technologies de télédétection permettent aux utilisateurs d'acquérir des informations détaillées sur la surface de la Terre, à différentes échelles, de manière synoptique et temporelle. Ces technologies connaissent actuellement une révolution technique avec l'évolution rapide de la conception des capteurs. À la suite de cette révolution technique, le radar à synthèse d'ouverture (RSO/SAR), l'un des meilleurs exemples de système de télédétection hyperfréquence actif, est devenu un outil d'investigation exceptionnel pour de nombreuses missions où les capteurs visibles sont mal adaptés, grâce à sa capacité d'observer la surface de la Terre à tout moment et dans toutes les conditions météorologiques [1], [2].

Face à cette abondante quantité de données, l'extraction d'informations thématiques souhaitées, offertes par la télédétection, nécessite une définition de techniques d'analyse automatiques, ce qui aidera à la prise de décision pour un large éventail d'applications. L'une des principales applications des données de télédétection est la détection du changement des caractéristiques de la surface de la Terre, largement utilisée dans divers domaines, tels que la planification urbaine [3], l'évaluation environnementale [4], l'enquête agricole [5], la surveillance des catastrophes [6] et les changements forestiers [7]. Cette application incarne l'un des sujets de recherche les plus cruciaux et les plus distingués dans le domaine de la télédétection, puisqu'elle fournit une bonne base permettant de mieux comprendre les relations et les interactions entre les phénomènes humains et naturels afin de mieux gérer et utiliser les ressources.

Parallèlement à cette augmentation de la disponibilité des images brutes, les technologies de vision par ordinateur ont démontré un développement remarquable, en grande partie grâce à l'apprentissage automatique qui a connu une croissance sans précédent due à la croissance exponentielle de la puissance de calcul, de nouveaux algorithmes et d'une pléthore de nouvelles applications enrichissantes.

L'apprentissage en profondeur (deep learning) étant le paradigme le plus précis, s'est dès lors avéré possédant des capacités inégalées dans de nombreux domaines. Il a en fait initié une nouvelle vague de recherches prometteuses dans de nombreuses tâches d'analyse d'images

grâce à sa grande capacité d'apprentissage hiérarchique des caractéristiques représentatives et discriminantes.

Couronné de succès dans presque tous les domaines, l'apprentissage en profondeur a pris son envol dans les applications de télédétection, il est de plus en plus le modèle de choix dans les modèles de détection de changements, ce qui peut réduire la forte dépendance au travail manuel et offrir une nouvelle méthode de traitement automatique et perspicace pour répondre aux exigences actuelles.

Les données de télédétection présentent ainsi de nouveaux défis sans précédent pour l'apprentissage en profondeur, car l'analyse d'images satellitaires pose des problèmes particuliers qui génèrent de nouvelles questions scientifiques ardues. C'est dans ce cadre que s'inscrit cette thèse qui met l'accent sur la tâche de détection de changements.

Notre travail ambitionne d'apporter de nouvelles contributions, d'améliorer les performances et la précision des modèles de détection actuels sans introduction de calculs additionnels, en réduisant la complexité des modèles de détection afin de les rendre plus efficaces.

Problématiques et objectifs

Malgré la complexité du traitement des données et le grand nombre de sources d'erreurs [8], [9], les capteurs radar à synthèse d'ouverture (SAR) se sont avérés particulièrement propices pour répondre aux applications de détection de changements. Du point de vue opérationnel, l'utilisation des capteurs Radar dans la détection de changements est de plus en plus intéressante. D'énormes progrès ont été réalisés ces dernières années, et de nombreuses techniques de détection de changements ont montré des performances impressionnantes.

Bien qu'il y ait plusieurs travaux liés aux techniques de détection de changements appliquées aux images radar à ouverture synthétique (SAR), il ressort clairement que le problème demeure un sujet actif d'investigation, de plus que la recherche de méthodes efficaces demeure constamment en développement.

Dans cette thèse, nous visons à développer des méthodes avancées de détection de changements en imagerie SAR capables de traiter efficacement toutes les problématiques qui s'avèrent être une tâche substantiellement complexe. Nous concentrons notre attention sur deux défis :

- Le radar à synthèse d'ouverture (SAR) est un système d'imagerie cohérent [8]. Chaque pixel des images SAR représente l'addition cohérente de diffuseurs à partir d'une cellule de résolution correspondante. Ces diffuseurs interfèrent, de manière constructive ou destructive, selon la phase des diffuseurs. Ainsi, les images obtenues présentent des pixels clairs et sombres qui sont inégales, même pour des régions homogènes. Ce phénomène est appelé bruit de chatoiement (speckle). Un bruit multiplicatif entraîne une dégradation de la qualité de l'image et entrave l'interprétation des données, affectant ainsi les performances de la détection de changements.

Ainsi, notre premier défi est de surmonter l'impact du bruit de chatoiement, qui requiert souvent un prétraitement de l'image, notre objectif est de proposer un nouvel algorithme de suppression du bruit qui non seulement élimine le bruit, mais préserve également les bords et les textures.

La détection de changements vise à identifier les changements intervenus sur le terrain entre deux ou plusieurs acquisitions sur une même zone géographique à des instants différents, notre but étant de générer une carte de changements, qui identifie le changement dans chaque pixel à deux instants différents de la scène, cela peut être formulé comme un problème de classification où la sortie finale est une image binaire.

Dans ce contexte, notre deuxième défi sera lié à la conception des classificateurs puissants, sachant qu'il s'agit de l'étape la plus cruciale de tout l'algorithme, qui détermine les résultats finaux de la détection de changements.

Contributions et perspectives

La détection de changements est un processus qui analyse deux ou plusieurs images capturées sur la même zone géographique à des moments différents pour identifier les changements importants de couverture terrestre qui se sont produits. Elle présente l'une des applications les plus critiques des technologies de télédétection. Avec l'augmentation fulgurante des données de télédétection, la détection précise du changement est un axe de recherche très prometteur, vu qu'il met au premier plan de nouveaux défis, tel l'automatisation, la robustesse et l'efficacité.

L'intelligence artificielle a récemment instauré de nouvelles perspectives pour la surveillance et l'évaluation de l'environnement. Cela est principalement dû à l'avancement des

approches d'apprentissage automatique et l'exploration de données, qui facilitent l'extraction d'informations significatives à grande échelle, à partir de sources géoréférencées et hétérogènes.

Dans cette thèse, de nouvelles approches sont conçues pour la recherche et la visualisation de modèles multiples pour le problème de détection de changements. Nous visons ainsi à élargir les recherches actuelles sur l'application de l'apprentissage profond audit problème, conduisant à des techniques de détection capables d'identifier les zones dans les images de télédétection où la couverture/l'utilisation des terres a changé.

La thèse aspire à fournir trois nouvelles contributions à l'état de l'art :

La première contribution : Un élément clé du succès de l'apprentissage en profondeur est la disponibilité de quantités massives de données de formation. L'élaboration et l'annotation de grands ensembles de données pour résoudre les problèmes de détection de changements d'image SAR constituent aujourd'hui un goulot d'étranglement pour de nombreuses applications.

Face à ce défi et à l'effet du bruit qui affecte inévitablement la performance des résultats finaux, notre première contribution incarnera une nouvelle structure destinée à atténuer ces problèmes en tirant parti des réseaux de neurones profonds.

À cette fin, nous avons proposé un réseau de croyances profondes (DBN) en tant qu'architecture profonde qui comprend un apprentissage non supervisé des fonctionnalités suivi d'un réglage fin du réseau supervisé, sachant que les méthodes non supervisées sont généralement privilégiées par rapport à leurs homologues supervisés en raison de la difficulté de produire des données étiquetées. Les réseaux de neurones profonds peuvent atteindre les cartes de changement finales, directement à partir des deux images originales.

En outre, pour minimiser l'effet du bruit, une pré-classification basée sur la reconstruction morphologique et le filtrage des membres est proposée.

Les réseaux profonds nécessitent généralement de nombreux échantillons de haute qualité pour l'optimisation des paramètres. Afin d'atténuer le surajustement provoqué par des données SAR limitées, une méthode de génération d'échantillons virtuels est utilisée pour fournir un ensemble de données avec un volume et une diversité de données appropriés pour la formation du réseau. Les résultats expérimentaux ont indiqué que la méthode proposée avait un temps de mise en œuvre acceptable, en plus de ses performances souhaitables et de sa grande précision.

La deuxième contribution : Récemment, l'apprentissage en profondeur (DL), en particulier le réseau neuronal convolutif (CNN), a été largement appliqué au domaine de la détection de changements, grâce à son processus simple, sa forte capacité de représentation des caractéristiques et ses excellentes performances d'application. Il a montré une robustesse surclassant les autres modèles neuronaux, ainsi que les performances humaines.

Cependant, leur succès dépend de la disponibilité de très grandes bases de données représentatives de toutes les variations de la source d'entrée, ce qui constitue un problème lorsqu'il s'agit des données SAR. De plus, avec la présence de bruit de speckle et une acquisition précise des données qui est coûteuse et qui prend du temps, il est difficile d'entraîner efficacement le réseau, ce qui limite davantage le développement de la détection de changements.

Récemment, les réseaux de capsules ont été introduits comme une architecture alternative d'apprentissage en profondeur et une approche de formation pour modéliser la variabilité spatiale/point de vue d'un objet dans l'image. Bien qu'ils en soient encore à leurs débuts, ils ont reçu une attention considérable au sein de la communauté. Leurs applications aux études liées à la détection de changements dans les images radar reste cependant assez rare.

Notre seconde contribution consiste à proposer une nouvelle approche de détection de changements robuste en tirant parti de l'avantage du réseau de capsules pour extraire l'information discriminante entre les images SAR multitemporelles.

Pour résoudre le problème du bruit de speckle, divers modules d'attention sont conçus pour convertir les intensités de pixels en activités caractéristiques locales. En conséquence, les caractéristiques locales deviennent robustes au bruit.

Des expériences approfondies sur des jeux de données réels sont menées pour montrer l'efficacité et la supériorité de la méthode proposée par rapport à de nombreuses méthodes de pointe.

La troisième contribution : Différentes des données SAR conventionnels (c'est-à-dire les systèmes SAR à polarisation unique), les données PolSAR multicanaux et multiparamètres obtenues en transmettant et en recevant des ondes électromagnétiques dans différents états polarimétriques. Ces données jouent un rôle important dans la télédétection radar, puisqu'elles peuvent fournir des informations physiques et géométriques améliorées sur la cible en analysant les comportements des rétrodiffusées ondes électromagnétiques polarisées, ce qui conduit à une amélioration de la qualité de la carte de détection de changements.

Les recherches menées dans cette thèse mettent en évidence de nombreuses perspectives à explorer. Il serait ainsi intéressant d'élargir notre travail à d'autres types de système SAR tels que les systèmes SAR polarimétriques.

Notre troisième contribution consiste à proposer un nouvel algorithme de détection de changements basé sur l'apprentissage en profondeur pour l'imagerie radar à synthèse d'ouverture polarimétrique (PolSAR), qui constituera notre prochain objectif de recherche.

Structure de la thèse

La thèse est structurée en cinq chapitres qui reflètent la progression de la recherche et divisent les problèmes et hypothèses en sections distinctes.

Chapitre 1 : vise à fournir au lecteur les notions de base et les concepts préliminaires concernant le radar à synthèse d'ouverture. Le principe de l'imagerie SAR polarimétrique sera succinctement abordé pour exposer les éléments clés nécessaires à la compréhension des mesures polarimétriques. Ces concepts seront utilisés tout au long de cette thèse.

Chapitre 2 : décrit brièvement les grandes familles de méthodes existantes, les problèmes et les défis rencontrés lors de la détection de changements. Une analyse comparative entre les différentes techniques est prise en considération.

Chapitre 3 : présente notre initiale contribution, basée sur l'article, ainsi documenté : **"Unsupervised change detection method in SAR images based on deep belief network using an improved fuzzy C-means clustering algorithm"**, *IET Image Processing* 15 (4) (2021), pp. 974-982. <https://doi.org/10.1049/ipr2.12078>

Une méthodologie originale a été proposée vise à améliorer les résultats de la méthode de détection de changements SAR en se basant sur des architectures profondes. L'objectif étant de mieux former le réseau en augmentant les échantillons de diversité appropriés, d'une part, et de réduire au minimum l'effet du bruit, d'autre part.

Chapitre 4 : présente notre seconde contribution, s'appuyant sur l'article intitulé : **"Multidimensional parallel capsule network for SAR image change detection"**, *Multimed Tools Appl* (2022). <https://doi.org/10.1007/s11042-022-13622-4>.

Ce chapitre préconise une approche innovante dans laquelle le problème de détection de changements est traité en exploitant l'avantage du réseau de capsules.

Chapitre 5 : propose un nouveau cadre de détection de changements profond pour l'imagerie radar synthétique à ouverture polarimétrique (PolSAR), lequel constituera notre prochain objectif de recherche.

Enfin, la thèse est clôturée par une nécessaire tentative d'auto-évaluation et en renseignant subséquemment par d'autres perspectives d'investigation.

Chapitre 1

L'IMAGERIE SAR/PolSAR : Atouts et restrictions pour l'observation terrestre

Le présent chapitre vise dans un premier temps à fournir au lecteur des notions de base sur le radar à synthèse d'ouverture, suivis des concepts de la polarimétrie radar, en vue de le familiariser avec la terminologie utilisée tout au long de cette thèse. Les atouts et les limitations de l'imagerie radar sont abordés à la fin.

1.1 Introduction

Une avancée significative dans l'imagerie de surface en sciences de la Terre, fut liée à l'avènement de l'imagerie hyperfréquence (ondes RADAR ou micro-ondes) et la mise en orbite de satellites actifs.

Un radar est un système qui permet de détecter et/ou localiser et/ou déterminer la vitesse d'objets en utilisant des ondes radio. Le terme RADAR est le sigle de l'expression américaine RADIO Detection And Ranging. Il désigne aussi bien l'instrument de mesure que la technique s'appuyant sur celui-ci. Ses premières applications ont été orientées dans le sens de la détection et de la localisation, avant d'être utilisé en tant que système imageur.

Embarqué généralement sur des objets mobiles (avion, satellite, etc..), le système radar transmet des impulsions successives d'ondes électromagnétiques pour éclairer une scène cible, puis reçoit et enregistre l'écho de chaque impulsion émise. La diffusion de l'impulsion hyperfréquence transmise est principalement déterminée par la géométrie et les propriétés diélectriques de la cible et la configuration d'émission/réception du capteur.

Son mode de fonctionnement actif signifie qu'il a sa propre source d'énergie pour éclairer la zone d'imagerie, le rend indépendant de l'éclairage solaire, d'où sa capacité d'imagerie de jour

et de nuit contrairement au système optique qui dépend de l'éclairement d'une source extérieure. De plus, son fonctionnement dans la partie micro-ondes du spectre électromagnétique, généralement entre la bande P (0,25-0,5 GHz) et la bande Ka (25-40 GHz), rend les effets des nuages, du brouillard, de la pluie, des fumées, etc. le plus souvent évités. Cette propriété lui permet d'acquérir des images dans presque toutes les conditions météorologiques, d'où son appellation capteur tout-temps. En outre, la puissance de pénétration de l'onde électromagnétique émise, lui offre des possibilités de détection d'objets à travers le feuillage ou à travers des parois. Enfin, connaissant les caractéristiques du signal diffusé émis, l'analyse des rétrodiffusions reçues, en termes de décalages de fréquence et de polarisation, permet d'extraire, avec une grande précision, les propriétés de la surface éclairée. Par exemple, il est possible de récupérer des informations sur l'état des champs pour l'agriculture [9] et la détection d'anciennes caractéristiques du paysage et les transformations anthropiques [10].

Les systèmes radar ont de nombreuses conceptions différentes, y compris le radar aéroporté à visée latérale (SLAR) (Side Looking Aperture Radar) et le radar à synthèse d'ouverture (SAR). Le premier est le plus ancien et le plus simple. Un tel système fonctionne sur le principe d'émettre de courtes impulsions d'énergie micro-ondes et d'enregistrer la réflexion d'une zone donnée au sol. La seconde conception est la forme la plus connue d'imagerie radar. Il s'agit d'une technique de radar spéciale permettant d'obtenir des images de réflectivité bidimensionnelle (2D) à haute résolution spatiale de la surface de la Terre.

Comprendre la télédétection avec l'imagerie radar peut être plus difficile car la technologie elle-même est plus compliquée et les données d'image enregistrées sont plus variées. Comme il y a tellement de concepts et de techniques à assimiler, ce premier chapitre a pour ambition de familiariser le lecteur avec les concepts et la terminologie utilisés tout au long de cette thèse.

Dans un premier temps, une brève introduction au radar à synthèse d'ouverture (RSO) ou Synthetic Aperture Radar (SAR) sera présentée. Y seront également exposées sa configuration géométrique et sa résolution spatiale.

Dans un second temps, grâce à la propriété de polarisation des ondes électromagnétiques, les systèmes SAR appelés PolSAR sont capables d'émettre et de recevoir des ondes polarisées orthogonalement à la fois dans la transmission et la réception, ce principe sera succinctement abordé pour donner les éléments clés nécessaires à la compréhension des mesures polarimétriques.

1.2 Radar à Synthèse d'Ouverture (RSO/SAR)

Le Radar à Synthèse d'Ouverture (RSO) est appelé Synthetic Aperture Radar (SAR) en anglais. L'idée derrière cette technologie était de résoudre les limitations de résolution spatiale des radars de cette époque. En effet, la résolution spatiale d'une antenne est inversement proportionnelle à sa taille. Améliorer la résolution revient donc à obtenir une antenne d'une taille qui était impraticable sur des capteurs aéroportés ou spatiaux. Les systèmes SAR ont pu résoudre ce problème, représentant ainsi une nette avancée, les ingénieurs ont trouvé une solution astucieuse en tirant parti du mouvement des capteurs pour créer une antenne synthétique équivalente plus grande. Selon ce concept, une séquence d'acquisitions cohérentes réalisées à partir des positions de trajectoire successives d'une antenne réelle plus courte, est combinée pour simuler une antenne beaucoup plus grande, fournissant ainsi des données à plus haute résolution. Similaire à d'autres systèmes actifs, Le radar à synthèse d'ouverture est une technologie d'imagerie qui transmet et reçoit des signaux dans le spectre électromagnétique. Le but du traitement du signal SAR est de synthétiser une image 2D à haute résolution spatiale de la réflectivité de la surface de la Terre à partir de tous les signaux reçus.

Pour une introduction détaillée à la SAR, le lecteur peut se référer aux livres tels que [11], [12],[13], [14].

1.2.1 Géométrie d'acquisition des images SAR

La géométrie du radar imageur souvent utilisé pour l'observation de la Terre est illustrée dans la Figure 1.1.




Figure 1.1: Géométrie d'une acquisition SAR

Le sol est cartographié dans un système de coordonnées composé de l'axe d'azimut (la direction de la trajectoire) et de l'axe de distance (la direction de propagation des ondes). Tout en se déplaçant, l'antenne radar émet périodiquement des impulsions micro -ondes vers le sol avec un angle de visée latérale θ dans la direction perpendiculaire à la trajectoire de vol (direction azimutale) et mesure ensuite l'écho recueilli par la même antenne. L'angle θ correspond à l'angle entre l'axe central du lobe d'antenne et le Nadir.

La géométrie latérale est importante pour éliminer les ambiguïtés droite-gauche de deux points symétriques équidistants [13] [15] . Le taux de répétition des impulsions, ainsi que la largeur de bande peuvent varier considérablement d'un système à l'autre. La succession des impulsions émises latéralement par le radar dont la fréquence est donnée par la PRF (Pulse Repetition Frequency) permet d'obtenir des informations sur une bande continue de sol que l'on appelle la fauchée limitée par les portées (qui représentent la direction dans laquelle le radar émet et reçoit le rayonnement) proximale et distale du satellite. La zone couverte par le faisceau d'antenne dans la distance au sol (X) et l'azimut (Y) correspond à l'empreinte de l'antenne. Cette zone est constituée de nombreuses petites cellules. L'écho rétrodiffusé par chaque cellule au sol dans l'empreinte va permettre la formation de l'image. Cet écho est ainsi reçu et enregistré sous la forme d'un pixel dans le plan image en fonction de la distance oblique entre l'antenne et la cellule au sol.

L'image SAR obtenue est une image comportant en chaque pixel une valeur d'amplitude et de phase :

- La phase est utilisée pour déterminer la distance entre le capteur et une cible.
- L'amplitude indique la quantité de signal envoyé qui revient au capteur, les mesures d'amplitude fournissent des informations sur la rugosité, la géométrie, l'humidité et la constante diélectrique de cette cible.

Les mesures de phase sont utilisées pour Le SAR interférométrique (une technologie qui utilise la différence de phase entre deux images radar à synthèse d'ouverture cohérentes d'une scène, obtenues par deux récepteurs séparés par une distance transversale appelée ligne de base, pour mesurer la hauteur de la surface imagée).

Les ouvertures d'antenne (appelées largeur de faisceau d'antenne) dans la direction transversale (portée) et le vol (azimut) la direction est donnée par :

$$\omega_v = \frac{\lambda}{M} \qquad \omega_h = \frac{\lambda}{D} \qquad (1.1)$$

Où M et D correspondent aux dimensions physiques de l'antenne dans les directions distance et azimuth, respectivement, et λ est la longueur d'onde correspondant à la fréquence porteuse du signal émis.

La fauchée WG peut alors être approximé par :

$$WG \approx \frac{\lambda R_m}{M \cos \theta} = \frac{\lambda H_{sat}}{M \cos^2 \theta} \quad (1.2)$$

Où R_m est la distance oblique entre le centre de l'antenne et le centre de l'empreinte ; H_{sat} est la hauteur de l'orbite du satellite au-dessus de la Terre.

1.2.2 Résolution spatiale des images SAR

La résolution spatiale est l'un des principaux paramètres d'intérêt lors de la conception d'une application impliquant des images SAR. Cette quantité représente la capacité du capteur à séparer deux diffuseurs rapprochés [16] : la distance minimale nécessaire permettant de distinguer deux réflecteurs sur une image radar.

Dans les systèmes SAR, il existe deux résolutions, **la résolution radiale** où la résolution en distance δ_g (slant-range en anglais) correspond à la direction perpendiculaire à la direction du vol et d'autre part **la résolution azimuthale** δ_y correspond à la direction parallèle à la direction du vol.




Figure 1.2: Résolution spatiale des images SAR

La résolution radiale où la résolution en distance dépend des propriétés de l'impulsion émise et elle est directement proportionnelle à la durée de l'impulsion transmise τ .

Considérons deux cibles ponctuelles M_1 et M_2 qui donnent lieu à des échos radar, séparées par une distance δ_g , comme illustré dans la Figure 1.2. La capacité de séparer ces deux cibles dans le signal reçu par le radar est déterminée par le fait que les impulsions de retour sont distinguables. Si les cibles sont trop proches leurs échos se chevaucheront et ils ne pourront pas être séparés dans le signal reçu.

La distance δ_g la plus courte qui est mesurée en tant que résolution radiale réalisable est donnée par [13] :

$$\delta r = \frac{c \tau}{2} = \frac{c}{2B} \quad (1.3)$$

Où B est la bande passante du signal, si nous projetons géométriquement δ_r sur le sol avec un angle d'incidence θ , nous obtenons la résolution en distance au sol qui est plus grossière que la résolution de distance oblique.

$$\delta_g = \frac{\delta r}{\sin \theta} = \frac{c \tau}{2 \sin \theta} \quad (1.4)$$

Si en vise à la verticale ($\theta = 0$), on ne peut pas définir de résolution, d'où l'intérêt de la visée latérale. Pour améliorer significativement cette résolution, soit augmenter l'angle de visée θ , soit réduire la largeur d'impulsion τ .

L'énergie d'une impulsion étant égale à $E = P \tau$. Où P est la puissance crête instantanée, caractérise la capacité de l'impulsion à détecter une cible. Pour assurer une capacité de détection élevée, une énergie d'impulsion élevée est souhaitable, ceci peut être réalisé en augmentant la puissance crête P . Toutefois, notamment pour les satellites d'imagerie radar, la puissance maximale est limitée par le matériel du capteur.

L'autre possibilité consiste à augmenter la durée des impulsions afin de maintenir un niveau d'énergie adéquat et de garantir la détection. Mais selon (1.3), une impulsion longue correspond à une bande passante étroite B , ce qui se traduit par une mauvaise résolution en distance.

Pour pallier cette difficulté, la technique de compression d'impulsion reste la plus fréquente. La technique consiste à émettre un signal modulé linéairement en fréquence

($\phi = 2 \pi \left(f_c t + \frac{k t^2}{2} \right)$, ϕ est la phase du signal émis) connu sous le nom de chirp, de durée τ , ainsi l'énergie du signal est étalée sur une large bande passante $B = k \tau$.

À l'aide d'un filtre d'adaptation, l'énergie est à nouveau comprimée dans un court intervalle de temps dans le récepteur. Ainsi, la durée d'impulsion et le rapport signal-bruit (SNR) sont augmentés sans réduire la résolution en distance.

1.2.2.2 Résolution en azimuth

Selon la théorie des ondes électromagnétiques, la résolution en Azimut dépend fortement de la distance radiale R (distance entre le radar et l'objet rétrodiffusant) et de l'ouverture de lobe d'antenne. (Figure 1.2), définie par [17] :

$$\delta_y \approx \frac{R \lambda}{D} = \frac{H_{sat} \lambda}{D \cos \theta} \quad (1.5)$$

Où λ représente la longueur d'onde associée à la fréquence porteuse, et D , comme déjà indiqué, est la longueur de l'ouverture de l'antenne radar.

L'augmentation de la longueur de l'antenne améliore la résolution d'azimut mais, néanmoins, conduit à des antennes de très grande longueur. En effet, pour un radar, $\lambda = 5,3\text{cm}$ se déplaçant sur un porteur à $R = 853\text{km}$ d'altitude, et l'antenne de longueur $D = 10\text{m}$ alors la résolution azimutale $\delta_y = 4.5\text{cm}$. Ce qui est considéré insuffisant pour les applications d'imagerie.

Atteindre une résolution métrique comparable à celle des systèmes optiques avec des antennes dont les dimensions sont restreintes, consiste à synthétiser une antenne apparemment longue en utilisant le mouvement linéaire vers l'avant de la plate-forme spatiale [11].

En exploitant le décalage de fréquence Doppler [18] provoqué par le mouvement relatif entre l'antenne et la cible, cette technique est basée sur le fait que la réponse d'un diffuseur est contenue dans plus d'un seul écho radar. Un point de diffusion est observé par le radar à partir de différentes positions pendant le mouvement de l'antenne sur son orbite (Figure 1.3).

Par conséquent, au lieu d'utiliser une grande antenne, une combinaison cohérente de différents échos par rapport à un point de diffusion réalise une antenne synthétique élargie.

Une sorte de réseau d'antennes situées le long d'une seule ligne équivaut à une seule antenne se déplaçant le long de cette ligne tant que les signaux reçus par cette seule antenne sont enregistrés

de manière cohérente et additionnés de la même manière que les signaux du réseau seraient combinés dans un réseau de guides d'ondes.




Figure 1. 3: Géométrie d'imagerie SAR- Le point de diffusion est visible par l'antenne à partir de divers emplacements (Figure extraite de [20])

La résolution en azimuth du SAR est significativement améliorée et donnée par :

$$\delta_y = \frac{D}{2} \quad (1.6)$$

Cela signifie que la résolution azimuthale d'un SAR n'est déterminée que par la longueur de l'ouverture réelle, quelle que soit la distance séparant le capteur de la zone imagée.

1.3 Imagerie SAR polarimétrique

La polarisation est une propriété fondamentale des ondes électromagnétiques, qui est définie par les orientations des vecteurs de champ électrique et magnétique. Dans ce contexte, la polarimétrie radar est une technique qui permet de décrire les propriétés de la cible en modifiant l'état de polarisation des ondes électromagnétiques [19], [20].

À la différence des données radar conventionnels (c'est-à-dire les systèmes SAR à polarisation unique), le radar polarimétrique à ouverture synthétique (PolSAR) fournit plus d'informations de diffusion. La section suivante aborde donc la polarimétrie SAR et son formalisme mathématique connexe.

1.3.1 Les représentations polarimétriques

1.3.1.1 Matrice de diffusion

La grandeur fondamentale mesurée par un radar polarimétrique à chaque pixel et à chaque fréquence est la matrice de Sinclair [21] ou matrice de diffusion cible [S] d'ordre 2 à éléments complexes :

$$S = \begin{pmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{pmatrix} \quad (1.7)$$

Pour comprendre comment la matrice de diffusion est construite, considérons un système SAR polarimétrique qui utilise une antenne conçue pour émettre et recevoir des ondes électromagnétiques d'une polarisation spécifique, les deux polarisations les plus courantes étant la linéaire horizontale H et la linéaire verticale V.

En raison du changement possible de polarisation de l'onde diffusée, l'antenne radar est conçu pour recevoir simultanément les différentes composantes de polarisation et, par conséquent, les données HH, VV, HV et VH seront disponibles dans un système polarimétrique complet [22] .

Les champs EM incident et diffusé polarisés peuvent être exprimés à l'aide des vecteurs de Jones E^i et E^s :

$$E_i = \begin{bmatrix} E_H^i \\ E_V^i \end{bmatrix} \quad E_s = \begin{bmatrix} E_H^s \\ E_V^s \end{bmatrix} \quad (1.8)$$

$(E_H^i, E_V^i), (E_H^s, E_V^s)$ Sont les vecteurs de Jones représentant les ondes incidentes et rétrodiffusées.

Ainsi, les champs électriques de l'onde diffusé E_s et de l'onde incidente E_i sont liés par une matrice de diffusion complexe [S] associée à chaque cellule de résolution de l'image selon [23].

$$\begin{bmatrix} E_H^s \\ E_V^s \end{bmatrix} = \frac{e^{-jkR}}{R} [S] \begin{bmatrix} E_H^i \\ E_V^i \end{bmatrix} = \frac{e^{-jkR}}{R} \begin{pmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{pmatrix} \begin{bmatrix} E_H^i \\ E_V^i \end{bmatrix} \quad (1.9)$$

Où K désigne le nombre d'onde et R représente la distance entre le radar et la cible, $j = \sqrt{-1}$ est l'unité imaginaire.

Le terme $\frac{e^{-jkR}}{R}$ prend en compte les effets de propagation à la fois en amplitude et en phase.

La matrice de diffusion [S] est obtenue à partir des grandeurs et des phases mesurées par les quatre voies d'un radar polarimétrique. Elle contient l'intégralité de l'information

polarimétrique, avec des entrées S_{HH} , S_{VH} , S_{HV} , S_{VV} , dont elles désignent les composants correspondants des champs électriques rétrodiffusés, Le premier indice fait référence à la polarisation de l'antenne d'émission, et le second à celle de l'antenne de réception, de sorte que HV fait référence à la combinaison d'une antenne d'émission polarisée H et d'une antenne de réception polarisée V.

Les termes S_{HH} et S_{VV} sont nommés « copolarisés ou de co-polarisation », alors que les termes S_{VH} et S_{HV} sont nommés « cross-polarisation ou canaux en polarisation croisée ».

Pour un système SAR monostatique, cas majoritaire dans le cas du radar satellite, dans lequel la même antenne réalise l'émission et la réception, les termes hors diagonale de [S] sont égaux, $S_{VH} = S_{HV}$, [14] , [24] , la matrice de diffusion est par conséquent une matrice symétrique.

Dans le cas contraire dit bistatique où deux antennes différentes sont utilisées pour l'émission et la réception, les termes de polarisation croisée ne sont généralement pas égaux $S_{VH} \neq S_{HV}$.

1.3.1.2 Vecteurs cible

Par projection sur une base orthogonale, La matrice de diffusion [S] peut être vectorisée, ce qui permet d'obtenir un vecteur cible, formé de quatre éléments complexes et qui contient toute l'information polarimétrique cohérente :

$$k_i = \text{tr}([S] \cdot [\Psi_i]) = \begin{bmatrix} k_0 \\ k_1 \\ k_2 \\ k_3 \end{bmatrix} \quad (1.10)$$

Où $\text{tr}(\cdot)$ désigne l'opérateur de trace et $[\Psi_i]$ est un ensemble complet de matrices de base de projection (2×2) qui sont construites comme une orthogonale placé sous le produit scalaire hermitien [22].

Les deux bases les plus utilisées pour choisir la structure de $[\Psi_i]$ sont $[\Psi_L]$ et $[\Psi_P]$.

La première base correspond à la base des matrices de Pauli donnée par :

$$[\Psi_P] = \left[\sqrt{2} \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \quad \sqrt{2} \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \quad \sqrt{2} \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \quad \sqrt{2} \begin{bmatrix} 0 & -i \\ i & 0 \end{bmatrix} \right] \quad (1.11)$$

La deuxième base correspond à l'ordonnancement lexicographique des éléments de la matrice [S] donnée par :

$$[\Psi_L] = \begin{bmatrix} [2 & 0] & [0 & 2] & [0 & 0] & [0 & 0] \\ [0 & 0] & [0 & 0] & [2 & 0] & [0 & 2] \end{bmatrix} \quad (1.12)$$

Les vecteurs de diffusion correspondant deviennent :

$$\vec{k}_P = \frac{1}{\sqrt{2}} \begin{bmatrix} S_{HH} + S_{VV} \\ S_{HH} - S_{VV} \\ S_{HV} + S_{VH} \\ i(S_{HV} - S_{VH}) \end{bmatrix} \quad \vec{k}_L = \begin{bmatrix} S_{HH} \\ S_{HV} \\ S_{VH} \\ S_{VV} \end{bmatrix} \quad (1.13)$$

Pour un milieu réciproque, dans le cas de la rétrodiffusion monostatique, le nombre d'éléments peut réduit à trois, les vecteurs de diffusion s'écrivent :

$$\vec{k}_P = \frac{1}{\sqrt{2}} \begin{bmatrix} S_{HH} + S_{VV} \\ S_{HH} - S_{VV} \\ 2S_{HV} \end{bmatrix} \quad \vec{k}_L = \begin{bmatrix} S_{HH} \\ \sqrt{2}S_{HV} \\ S_{VV} \end{bmatrix} \quad (1.14)$$

Ces vecteurs sont des représentations cohérentes de la matrice de diffusion, où les termes en $\sqrt{2}$ découlent de la nécessité de conserver la puissance totale diffusée, leur norme aussi appelée Span de la cible, tel que :

$$\text{Span}(S) = \|\vec{k}_L\|^2 = \|\vec{k}_P\|^2 = |S_{HH}|^2 + |S_{VV}|^2 + 2|S_{HV}|^2 \quad (1.15)$$

1.3.2 Représentations matricielles

La matrice de covariance [C] et la matrice de cohérence [T] sont généralement utilisées pour représenter des données SAR polarimétriques. À partir des vecteurs de diffusion cible $\vec{k}_P$ et $\vec{k}_L$, les éléments des deux matrices [C] et [T] correspondent aux corrélations complexes entre les éléments des vecteurs cible.

La matrice C est associée au vecteur de mesure en base lexicographique, alors que la matrice T est associée au vecteur de mesure en base de Pauli.

Dans le cas de la diffusion monostatique, $S_{VH} = S_{HV}$, les deux matrices sont définies comme suit :

$$C = \langle \vec{k}_L \cdot \vec{k}_L^{*t} \rangle = \begin{bmatrix} \langle |S_{HH}|^2 \rangle & \sqrt{2} \langle S_{HH} S_{HV}^* \rangle & \langle S_{HH} S_{VV}^* \rangle \\ \sqrt{2} \langle S_{HV} S_{HH}^* \rangle & 2 \langle |S_{HV}|^2 \rangle & \sqrt{2} \langle S_{HV} S_{VV}^* \rangle \\ \langle S_{VV} S_{HH}^* \rangle & \sqrt{2} \langle S_{VV} S_{HV}^* \rangle & \langle |S_{VV}|^2 \rangle \end{bmatrix} \quad (1.16)$$

$$T = \langle k_P \cdot k_P^{*t} \rangle$$

$$= \frac{1}{2} \begin{bmatrix} \langle |S_{HH} + S_{VV}|^2 \rangle & \langle (S_{HH} + S_{VV})(S_{HH} - S_{VV})^* \rangle & 2 \langle (S_{HH} + S_{VV}) S_{HV}^* \rangle \\ \langle (S_{HH} - S_{VV})(S_{HH} + S_{VV})^* \rangle & \langle |S_{HH} - S_{VV}|^2 \rangle & 2 \langle (S_{HH} - S_{VV}) S_{HV}^* \rangle \\ 2 \langle S_{HV}(S_{HH} + S_{VV})^* \rangle & 2 \langle S_{HV}(S_{HH} - S_{VV})^* \rangle & 4 \langle |S_{HV}|^2 \rangle \end{bmatrix} \quad (1.17)$$

Où "*" représente le conjugué complexe et $|\cdot|^2$ représente la valeur d'intensité.

Les deux matrices [C] et [T] portent les mêmes informations sur les amplitudes de diffusion polarimétrique, les angles de phase et les corrélations, les deux sont hermitiennes semi-définies positives. De plus, elles ont les mêmes valeurs propres mais des vecteurs propres différents [25].

Les éléments diagonaux de la matrice de covariance représentent les intensités multilook des polarisations linéaires et les éléments hors diagonale sont la corrélation croisée complexe entre les canaux, ils sont liés à la géométrie et aux propriétés électriques de la cible et peuvent être utilisées pour l'interprétation physique du mécanisme de diffusion.

Massonnet et Souyris [14] concluent que la structure des vecteurs propres [T] convient davantage aux analyses polarimétriques.

1.3.3 Décompositions polarimétriques

La technique de décomposition polarimétrique des cibles reste l'outil le plus prometteur [14] qui puisse fournir des interprétations physiques des observations PolSAR, elle décompose la matrice de rétrodiffusion mesurée en une combinaison de réponses plus simples, cela permet une meilleure identification des mécanismes de diffusion et donc une interprétation plus aisée des caractéristiques structurales des cibles.

De nombreuses approches de décomposition polarimétrique ont été proposées pour interpréter le mécanisme de diffusion présents dans les données PolSAR.

Selon les hypothèses des types de cibles, ces nombreux schémas de décomposition peuvent être divisés en deux grandes catégories : la décomposition de cible cohérente et la décomposition de cible incohérente.

Dans les sous-sections suivantes, nous proposons d'évaluer deux décompositions très populaires dans les chaînes de traitement des images radar polarimétrique, à savoir :

- La décomposition de Pauli

- La décomposition incohérente de Cloude et Pottier (1997).

Des informations plus détaillées sur les décompositions de cibles polarimétriques peuvent être trouvées dans [26], [20].

1.3.3.1 Décomposition cohérente

Les décompositions cohérentes sont applicables aux cibles pures ou cohérentes qui donnent une rétrodiffusion complètement polarisée, et ne peuvent pas bien caractériser les cibles distribuées basées sur la décomposition de la matrice de diffusion $[S]$. Son principal inconvénient est qu'elle ignore les effets de bruit de speckle élevés dans les données SAR complexes à un seul regard, ce qui peut être un facteur limitant pour l'interprétation physique des cibles cohérentes (i.e. point ou cible pure).

Parmi les décompositions cohérentes les plus répandues figurent la décomposition de Pauli [27] et la décomposition de Krogager [24] et Cameron [28].

➤ Décomposition de Pauli

La décomposition de diffusion cohérente la plus pertinente est la décomposition de Pauli. La matrice de diffusion $[S]$ est exprimée comme la somme complexe de mécanismes de diffusion que l'on cherche à identifier, à savoir la réflexion de surface, la réflexion paire (ou de doubles rebonds) et la réflexion de volume, où chaque mécanisme de diffusion élémentaire est associé à une matrice de base de Pauli comme suit :

$$[S] = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} = a[S]_a + b[S]_b + c[S]_c + d[S]_d \quad (1.18)$$

$$a[S]_a = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \quad b[S]_b = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \quad (1.19)$$

$$c[S]_c = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 0 \\ 1 & 1 \end{bmatrix} \quad d[S]_d = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & -j \\ j & 1 \end{bmatrix} \quad (1.20)$$

Où les coefficients complexes a , b , c et d qui déterminent la contribution de chaque composant de la base peuvent être obtenus comme :

$$a = \frac{S_{HH} + S_{VV}}{\sqrt{2}} \quad b = \frac{S_{HH} - S_{VV}}{\sqrt{2}} \quad c = \frac{S_{HV} + S_{VH}}{\sqrt{2}} \quad d = j \frac{S_{HV} - S_{VH}}{\sqrt{2}} \quad (1.21)$$

Dans le cas monostatique avec l'hypothèse réciproque, où $S_{VH} = S_{HV}$, la base de la matrice de Pauli dans Eq. (1.18) peut être réduit aux trois premières matrices conduisant à $d=0$.

D'après [29], les coefficients a, b et c représentent :

- Le coefficient "a" représente un simple rebond : surface plane, sphère, trièdre.
- Le coefficient "b" représente un double rebond : typiquement de réflexion sur un bâtiment
- Le coefficient "c" représente une diffusion de volume : souvent présent dans les zones de végétation.

La décomposition Pauli de la matrice de diffusion sert souvent à représenter l'information polarimétrique dans une seule image SAR. Une image RGB peut être créée avec les intensités $|a|^2$, $|b|^2$ et $|c|^2$, qui, comme indiqué précédemment, correspondent à des mécanismes de diffusion physique clairs. Ainsi, l'image couleur résultante peut être utilisée pour interpréter les informations physiques d'un point de vue qualitatif.

La codification la plus employée correspond à $|a|^2$: Bleu, $|b|^2$: Rouge, $|c|^2$: Vert.

La Figure 1.4 présente une image de référence RGB issue de la décomposition de Pauli, acquise par le système AIRSAUR de la NASA en 1988 au-dessus de la baie de San Francisco en Californie. La surface de l'océan ressort presque entièrement en bleu associée au mécanisme de diffusion d'une surface. De même, pour les zones forestières qui apparaissent en vert cela signifie bien le mécanisme de diffusion du volume et enfin les zones urbaines qui apparaissent en rouge indiquent clairement un mécanisme de diffusion du double rebond.




Figure 1.4: Image RGB dans la base de Pauli. $|S_{HH} + S_{VV}|^2$, $|S_{HH} - S_{VV}|^2$, $|S_{HV}|^2$

1.3.3.2 Décomposition incohérente

Les décompositions cohérentes peuvent uniquement être utilisées pour caractériser des diffuseurs cohérents ou purs et simples (cibles canoniques). Néanmoins, un pixel est généralement plus complexe et il est constitué de diffuseurs répartis en présence de bruit.

Afin de dépasser les limites de la décomposition cohérente, des techniques de décomposition incohérentes ont été développées et largement utilisées dans les applications d'image PolSAR.

Les décompositions sont exécutées sur les statistiques de second ordre (telles que la matrice de covariance C et la matrice de cohérence T) et peuvent fournir une meilleure interprétation de la diffusion sous-jacente des cibles distribuée.

Les décompositions sont : la décomposition basée sur les vecteurs propres/valeurs propres [30] et la décomposition basée sur un modèle [24].

➤ La décomposition de Cloude-Pottier

La décomposition par diffusion vecteurs propres-valeurs propres, également connue sous le nom de décomposition de Cloude-Pottier [30], est basée sur la décomposition propre de la matrice de cohérence T , et les résultats de la décomposition sont les paramètres d'entropie (H), d'anisotropie (A) et angles alpha (α).

Comme la matrice de cohérence T est une matrice hermitienne et semi-définie positive, elle peut se diagonaliser de la manière suivante :

$$T = [U] [\Lambda] [U]^H \quad (1.22)$$

Où

$$\Lambda = \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix} \quad (1.23)$$

$$[U] = \begin{bmatrix} e_{11} & e_{12} & e_{13} \\ e_{21} & e_{22} & e_{23} \\ e_{31} & e_{32} & e_{33} \end{bmatrix} \quad (1.24)$$

Λ désigne la matrice diagonale des valeurs propres, λ_i sont les valeurs propres réelles de $[T]$ qui suivent $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$, U est la matrice de vecteurs propres unitaire avec trois vecteurs propres orthogonaux $\vec{e}_1, \vec{e}_2$ et $\vec{e}_3$, comme indiqué ci-dessous :

$$[U] = [\vec{e}_1 \quad \vec{e}_2 \quad \vec{e}_3] \quad (1.25)$$

$$\vec{e}_i = [\cos \alpha_i, \sin \alpha_i \cos \beta_i e^{j \delta_k}, \sin \alpha_i \sin \beta_i e^{j \gamma_k}]^T \quad (1.26)$$

L'idée principale de l'approche des vecteurs propres est de décomposer la matrice T en une somme de trois matrices de cohérence indépendantes (orthogonales). Ainsi [T] peut être décomposé en trois parties :

$$T = \lambda_1 e_1 \cdot e_1^{*T} + \lambda_2 e_2 \cdot e_2^{*T} + \lambda_3 e_3 \cdot e_3^{*T} \quad (1.27)$$

Chaque partie de (1.27) présente une contribution de diffusion. La probabilité P_i de chaque mécanisme de diffusion qui représentent le poids de chaque valeur propre est exprimée de la manière suivante :

$$P_i = \frac{\lambda_i}{\sum_{k=1}^3 \lambda_k} \quad (1.28)$$

Les trois paramètres les plus utilisés obtenus à partir de valeurs propres et de vecteurs propres sont décrits ci-dessous :

- Le premier paramètre est **l'entropie polarimétrique H**, qui représente le degré de caractère aléatoire de la diffusion et varie de 0 à 1. Lorsque l'entropie est égale à zéro ($\lambda_2 = \lambda_3 = 0$), une valeur propre non nulle est présente et le processus de diffusion est décrit par une diffusion unique. Cependant, l'entropie se voit généralement attribuer une valeur comprise entre 0 et 1 pour les diffuseurs distribués (incohérents).

$$H = - \sum_{i=1}^3 P_i \log_{3P_i} \quad (1.29)$$

- Le second paramètre est **l'anisotropie A**, elle aussi comprise entre 0 et 1. C'est un paramètre complémentaire de l'entropie H et peut jouer un rôle important pour distinguer les différents types de diffusion lorsque l'entropie atteint une valeur élevée (quand $H > 0,7$)

$$A = \frac{\lambda_2 - \lambda_3}{\lambda_2 + \lambda_3} \quad (1.30)$$

- Le troisième paramètre est **l'angle alpha α** , qui représente le type de diffusion dominant la scène, elle varie entre 0° et 90° .

si $\alpha = 0^\circ$ la diffusion est liée au plan de la surface plane, alors que pour $\alpha = 45^\circ$, le résultat montre que les caractéristiques de diffusion sont celles d'un dipôle.

Entre (0° à 45°), c'est une surface irrégulière.

De $\alpha = 45^\circ$ à $\alpha = 0^\circ$ la réponse est le résultat d'un diffuseur à double rebond.

$$\alpha = \sum_{i=1}^3 P_i \alpha_i \quad (1.31)$$

Pour chaque vecteur propre ($\vec{e}_i$) l'angle alpha i est calculé comme suit et varie de 0° à 0°

$$\alpha_i = \arccos(|e_{1i}|) \quad (1.32)$$

En utilisant les paramètres α et H on peut former un espace à deux dimensions où une représentation plus précise du mécanisme sous-jacent est possible, où chaque pixel est caractérisé par une entropie et des valeurs d'angle alpha et renseigne sur le type de diffusion.

Il est subdivisé en 9 classes comme indiqué dans Figure 1.5.




Figure 1. 5: Plan H - α

1.4 Caractéristiques de l'imagerie SAR : Atouts et restrictions

Les données radar sont sujettes à de nombreux changements plus ou moins contrôlés (bruit du système de mesure, effet topographique, bruit de chatoiement (speckle) qui rendent

les valeurs mesurées incertaines. Il faut ainsi appréhender les phénomènes inhérents à la formation de l'image.

1.4.1 Distorsion géométrique

La géométrie latérale du SAR associée à un terrain non plat provoque des distorsions géométriques inhérentes de l'image résultante, telles que le raccourcissement et le déplacement du relief.

- **Raccourcissement (Foreshortening)** : il est causé par le temps de trajet plus court de l'impulsion radar, car la distance de portée oblique à un objet sur la pente inclinée est plus courte qu'à un objet sur des zones planes. Les zones raccourcies apparaissent plus lumineuses dans l'image SAR, en raison de la compression dans une partie d'image plus petite de la pente rétrodiffusée.

Comme le montre la Figure 1.6, la pente a-b est comprimée dans le plan oblique car le signal radar atteint le point b peu de temps après avoir atteint le point a dans le temps. Cela fait apparaître un objet haut avec une pente, comme une montagne, plus raide, avec une apparence de "bord" mince et plus brillante.

- **Repliement (lay-over ou fold-over)** : exemple extrême de raccourcissement, il apparaît sous forme d'une torsade, zone claire suivie d'une zone sombre puis à nouveau d'une zone claire. Lorsque la pente du terrain dépasse l'angle de visée radar, les diffuseurs sont imagés dans l'ordre inverse et se superposent à la contribution provenant d'autres zones. Illustré à la Figure 1.6, le point b au sommet de la montagne est plus proche du capteur radar, il est donc imagé sur le plan image plus tôt que le point au bas de la montagne. Par conséquent, l'écho de ab est distribué dans un ordre inverse sur le plan image (ab).
- **L'ombrage (shadowing)** : les ombres sont des zones où aucune rétrodiffusion n'est enregistrée au niveau du capteur, causé pour les mêmes raisons que les ombres formés dans l'imagerie optique : un objet bloque le chemin du rayonnement direct - la lumière visible dans le cas de l'imagerie optique et le faisceau radar dans le cas du SAR. Cela se produit lorsque les surfaces qui sont détournées du capteur sont plus raides que l'illumination SAR, comme le montre la Figure 1.6. La zone entre bd ne peut pas être éclairé par le faisceau radar, car bc est plus raide que le faisceau radar, ce qui provoque la zone d'ombre b'd'.




Figure 1. 6: Distorsion géométrique en imagerie SAR (<https://earth.esa.int/handbooks/asar/CNTR1-1-2.html>)

1.4.2 Interaction entre le signal Radar et le milieu

La rétrodiffusion radar mesure la quantité de rayonnement micro-ondes SAR réfléchi vers le capteur par la surface du sol. De nombreux facteurs l'influencent tels que :

- **La longueur d'onde** du système SAR affecte la résolution en azimuth et influence la pénétration du signal et, par conséquent, ce qui est imagé.

La bande X ($\sim 3.1\text{cm}$), la pénétration est faible permettant uniquement la caractérisation de la canopée.

La bande C ($\sim 5.5\text{cm}$), l'atténuation atmosphérique est faible, et la pénétration augmentant, il est possible d'obtenir des informations sur la structure de la canopée (feuilles, branches, etc.).

La bande L ($\sim 23\text{cm}$) a la plus grande pénétration dans l'ensemble, il n'y a pas d'atténuation atmosphérique et il est possible d'obtenir des images des couches situées sous la canopée, et donc de détecter la présence d'eau sous forêt, ce qui est impossible en optique. Les trois bandes pénètrent dans le sable sec, avec des retours plus forts à la fois

de la bande C et de la bande L. En général, la pénétration du radar augmente avec la longueur d'onde.

- **Rugosité de surface** : La force de la rétrodiffusion est partiellement basée sur la rugosité relative à la surface imagée par rapport à la longueur d'onde du système et à la constante diélectrique du matériau à partir duquel la diffusion se produit. Plus la surface est lisse, plus la réflexion s'éloigne du capteur, tandis que les surfaces rugueuses donnent un retour beaucoup plus fort vers la plate-forme d'imagerie. Pour une surface parfaitement lisse, le champ est entièrement diffusé dans la direction spéculaire. Par conséquent, aucune rétrodiffusion n'est enregistrée par le capteur.
- **La constante diélectrique relative et la perméabilité relative μ_r du matériau de surface** : l'influence de μ_r est négligeable et donc $\mu_r = 1$. La constante diélectrique est un nombre complexe qui dépend des propriétés diélectriques du matériau et varie en fonction de la teneur en humidité du matériau et de la fréquence SAR. Les matériaux à faible ϵ_r ont moins de réflectivité et donc une plus grande pénétration dans le milieu. Les objets métalliques et l'eau ont une constante diélectrique plus élevée et sont plus réfléchissants, mais comme ils sont lisses par rapport à la longueur d'onde du système et généralement plats, le faisceau radar est réfléchi de manière spéculaire, loin du capteur.

De plus, certaines caractéristiques de surface provoqueront une réflexion spéculaire vers le capteur, en rebondissant sur plusieurs surfaces. Une réflexion à double rebond est appelée un retour dièdre et un retour à triple rebond est appelé un retour trièdre. Celles-ci sont produites généralement sur deux surfaces perpendiculaires (par exemple, le sol et le mur du bâtiment).

1.4.3 Propriétés bruit de chatoiement (speckle)

La nature cohérente de l'onde radar et les interférences constructives et destructives entre les retours complexes des diffuseurs dans une cellule de résolution fait aboutir à une apparence granuleuse (sel et poivre) dans l'imagerie SAR. Cet effet, appelé chatoiement, provoque une variation d'intensité pixel à pixel même sur des zones homogènes, et donne à l'image SAR son aspect bruité.

Même si l'effet du bruit n'est pas aléatoire car il dépend des diffuseurs présents dans la scène, il est souvent modélisé comme un bruit aléatoire multiplicatif. Sa présence dans les images SAR perturbe fortement leur traitement et perturbe l'interprétation de leurs résultats.

1.5 Conclusion

La disponibilité croissante de capteurs SAR à résolution temporelle et spatiale offre une nouvelle perspective dans l'investigation et la surveillance des activités humaines.

Contrairement aux capteurs optiques passifs qui dépendent du soleil pour leur source de lumière, le radar à synthèse d'ouverture (SAR) est un système de télédétection actif doté de sa propre source de micro-ondes, ce qui lui permet d'acquérir des images jour et nuit, peu importe la lumière du soleil. Outre ces aspects, les capteurs SAR peuvent collecter des signaux dans différentes polarisations afin d'extraire des informations sur la structure physique de la cible observée.

Bien que la télédétection SAR présente de nombreux avantages par rapport aux systèmes de mesure optiques, les données SAR sont sujettes à certaines restrictions qui perturbent leur analyse.

Le présent chapitre constitue donc un fondement nécessaire à l'utilisation et à l'interprétation appropriées des données SAR.

Chapitre 2

Revue bibliographique des algorithmes de Détection de changements en imagerie SAR

Ce chapitre n'a pas vocation à fournir un état de l'art exhaustif de toutes les méthodes utilisées pour la détection de changements sur des images de télédétection SAR, mais plutôt de présenter les grandes familles de méthodes existantes et les problèmes et les défis rencontrés lors de la détection de changements. Une analyse comparative entre les différentes techniques est prise en considération.

2.1 Introduction

Avec une vue synoptique et une répétabilité, la télédétection par satellite peut fournir des informations opportunes, précises et cohérentes sur la surface de la Terre pour une surveillance rentable des changements environnementaux. Ces informations sont vitales pour la gestion des ressources naturelles, à la conservation des écosystèmes et de la biodiversité, ainsi qu'à l'appui des décisions en faveur du développement durable.

La détection de changements est l'une des principales applications des données de télédétection obtenues à partir de satellites en orbite terrestre, elle vise à distinguer les changements subtils et brusques dans une zone donnée, telles qu'elles se manifestent par des images de télédétection acquises à des moments différents [31]. Grâce au nombre croissant de programmes d'observation de la Terre tels que Sentinel, WorldView, GeoEye, ZY-3 et Gaofen, une variété de capteurs fournissent un grand nombre d'images de télédétection avec différentes résolutions pour les tâches de détection de changements.

Le radar à synthèse d'ouverture (SAR) a attiré une attention considérable en raison de ses avantages uniques, à savoir qu'il peut fonctionner dans presque toutes les conditions météorologiques et à tout moment. Les images SAR sont devenues une source de données

extrêmement importante pour la détection de changements, en particulier dans les zones où les données optiques sont rarement accessibles.

Diverses technologies de détection des changements SAR ont été développées ou sont en cours de développement, d'une simple différenciation vers des compétences d'apprentissage automatique, chaque technique a ses propres avantages et inconvénients.

À l'heure actuelle, aucune ne peut être qualifiée de méthode optimale et il n'existe pas de norme uniforme. L'examen de ces techniques est utile pour comprendre les vastes perspectives d'utilisation des données SAR pour la détection et la surveillance des changements.

2.2 Processus de détection de changements en imagerie SAR

Comme le montre la Figure 2.1, le processus conventionnel général de la détection de changements en imagerie SAR se compose d'environ quatre étapes : (1) Prétraitement d'image, (2) méthodes de détection de changements, (3) Évaluation des performances et (4) carte finale. Cette section explique les composants du processus et leurs interactions.




Figure 2. 1: Processus général de la détection de changements en imagerie SAR

2.2.1 Ensemble de données (Dataset)

Les ensembles de données de la détection de changements sur des images SAR sont toutes des images SAR multitemporelles en temps réel, contenant deux images enregistrées à des moments différents et une image de vérité terrain, comme indiqué dans la Figure 2.2.








Figure 2. 2: Ensemble de données de Wuhan : (a) image acquise le 14 octobre 2015 ;
(b) image acquise le 1er février 2016 ; et (c) l'image de vérité terrain

Le Tableau 2.1 énumère les ensembles de données SAR les plus fréquemment utilisés pour la détection de changements, y compris l'ensemble de données d'Ottawa, l'ensemble de données de Yellow river, l'ensemble de données de San Francisco et l'ensemble de données de Berne.

Tableau 2. 1: Illustration des ensembles de données SAR

Satellite	Zone	Nom du jeu de données	Date d'acquisition	Pixel	Image
RADARSAT SAR	Canada	Ottawa	Mai 1999 - Août 1999	290×350	
RADARSAT-2	China	Yellow river	Juin 2008 - Juin 2009	257×289	
ERS-2	US	San Francisco	Août 2003 - Mai 2004	256×256	
ERS-2	Switzerland	Bern	Avril 1999 - Mai 1999	301×301	

2.2.2 Prétraitement

La phase de prétraitement, est une étape cruciale en traitement d'image, elle vise à améliorer les données d'image en supprimant les distorsions indésirables ou en améliorant certaines caractéristiques de l'image pertinentes pour acquérir une meilleure précision dans les étapes suivantes. Ainsi, avant de mettre en œuvre la détection de changements, un processus de prétraitement d'image raisonnable et pratique est essentiel, principalement la correction géométrique, la correction de rayonnement et le débruitage d'image, etc., pour régler les problèmes liés aux effets de la variation de l'éclairage dans les conditions atmosphériques, de même que les problèmes liés aux changements saisonniers et aux attitudes des capteurs au moment de l'acquisition des images [32].

➤ **La correction géométrique et radiométrique** sont deux méthodes couramment utilisées.

- **La correction géométrique** vise à aligner géométriquement deux ou plusieurs images de la même scène obtenue à des moments différents à partir de différents points de vue et/ou par différents capteurs [33], ce qui peut être réalisé par un enregistrement ou co-enregistrement. Elle est requise dans toutes les techniques de détection de changements, car l'imagerie aérienne brute présente un certain degré de déformation géométrique. Ainsi, la correction géométrique est destinée à compenser les distorsions et éventuellement à créer une image avec un degré élevé de géométrie [34], [35] .

Si l'on ne tient pas compte des déformations géométriques dans les images, les coordonnées spatiales du pixel seront incorrectes. La correction géométrique est principalement utilisée pour identifier les changements d'image pris dans de nombreuses dimensions qui peuvent entraîner une mauvaise classification des pixels.

La correction géométrique peut être réalisée avec une coregistration grossière basée sur les coordonnées géographiques de chaque image ou par une coregistration fine basée sur la corrélation entre les diffuseurs forts. On peut aussi estimer un décalage de pixels en distance ou en azimuth et le corriger. D'autres méthodes basées sur la 2D-FFT de l'image permettent d'effectuer une coregistration sous-pixel en estimant le décalage entre les deux images dans le domaine fréquentiel [32].

En général, lorsque la résolution des images SAR est élevée, il devient plus difficile d'obtenir une coregistration satisfaisante.

▪ **La correction radiométrique** peut être appliquée pour normaliser des données multitemporelles obtenues sur des périodes distinctes, en éliminant les erreurs où les distorsions causées par les différences de rayonnement dans l'imagerie SAR. L'étalonnage et l'ajustement des données radiométriques sont essentiels lors de la comparaison de différents ensembles de données au fil du temps. Cette étape utilise deux approches distinctes : le calibrage absolu, dans lequel les nombres numériques sont convertis en valeurs de réflectance du sol correspondantes, et le calibrage relatif, qui est nécessaire pour calibrer correctement la sensibilité de déviation [36], [37].

Pour stabiliser la luminosité et le contraste dans les images satellites, la méthode de normalisation d'intensité est effectuée. Elle peut être évaluée en modifiant un histogramme d'image satellite selon les besoins [38].

Des corrections radiométriques sont également utilisées dans le modèle numérique d'élévation (DEM) pour améliorer la surface orientée de l'angle incident [39].

➤ **Débruitage d'image** : La réduction du bruit de chatolement est une étape critique car elle peut donner des résultats de détection de changements peu fiables si elle est effectuée de manière inexacte.

Diverses méthodes ont été proposées pour améliorer l'efficacité des techniques de la détection de changements, à savoir, le filtrage de Lee [40] , le filtrage Frost [41] et l'algorithme 3D de correspondance de Blocs (SAR-BM3D) [42] .

Des filtres multi-temporelles prenant en compte la corrélation du signal SAR entre les acquisitions d'images au fil du temps ont également été proposés [43] [44] ils incluent les caractéristiques inter-canaux dans les modèles statistiques utilisés, telles que l'indépendance du speckle et les variations temporelles de la réflectivité radar.

Dernièrement, les techniques de débruitage basées sur les algorithmes d'apprentissage profond sont devenues très populaire [45].

2.2.3 Techniques de détection de changements

Formellement, le problème de détection de changements entre deux images peut être défini comme suit :

On considère deux images SAR co-enregistrées I_1 et I_2 , de taille $M \times N$, acquises sur le même emplacement géographique à deux dates différentes t_1 et t_2 .

$$I_1 = \{I_1(i, j), 1 \leq i \leq M, 1 \leq j \leq N\} \quad (2.1)$$

$$I_2 = \{I_2(i, j), 1 \leq i \leq M, 1 \leq j \leq N\} \quad (2.2)$$

L'objectif principal est de produire une carte binaire (CM) représentant les changements survenus dans la scène entre t_1 et t_2 , en d'autres termes, attribuer à chaque pixel une étiquette binaire, dont une étiquette positive indique que la zone correspondant au pixel a changé, alors qu'une étiquette zéro représente une surface inchangée [46].

$$CM = \{CM(x, y) \in \{0, 1\}, 1 \leq x \leq W, 1 \leq y \leq L\} \quad (2.3)$$

Où (x, y) correspond aux coordonnées de position du pixel indexé i .

Ainsi, la détection de changements peut être considéré comme un cas particulier de classification thématique de l'occupation du sol.

Diverses méthodologies ont été développés et testés au fil des années pour contrôler l'utilisation des sols et l'évolution de la couverture terrestre et la littérature sur le sujet est dense. Selon l'étape de détection de changements dans laquelle l'étape de classification est effectuée, deux grandes approches sont présentées, à savoir la comparaison post-classification [47], [48] et l'analyse post-classification [49].

2.2.3.1 Détection de changements par comparaison post-classification

La détection de changements par comparaison post-classification est conceptuellement l'une des méthodes de détection de changements la plus simple, la carte de changement est identifiée en comparant des cartes de classification dérivées indépendamment des deux images SAR temporellement différentes de la même zone (Figure 2.3).

Cette méthode a l'avantage d'acquérir plus d'informations sur les catégories qui ont changé et empêche également la normalisation du rayonnement des images de télédétection, réduisant ainsi l'impact externe des différences sensorielles atmosphériques et environnementales entre les images de télédétection multitemporelles. Certains auteurs ont eu recours à l'approche, par exemple dans [50], [51], [52] ont utilisé des techniques de détection de changements de comparaison post-classification basées sur la classification supervisée par maximum de vraisemblance pour détecter les changements d'utilisation/de couverture terrestre et ont conclu que l'approche atteint une précision globale élevée pour une variété de données. De manière plus générale, cette approche est fortement influencée par la précision de classification de chacune des deux images. De plus, elle pourrait conduire à des résultats erronés notamment lors de l'utilisation d'images multi-dates ou multi-capteurs en raison des différences dans les

caractéristiques radiométriques des images à partir desquelles les cartes thématiques ont été obtenues [53].




Figure 2. 3: Cadre général de la détection de changements par comparaison post-classification

2.2.3.2 Détection de changements par analyse post-classification

La détection de changements par analyse post-classification, également appelé analyse de l'image de différence (DI), est actuellement le courant dominant avec d'excellentes performances, devenue névralgique de la recherche et suscite de plus en plus d'intérêt. Généralement basée sur une procédure en trois étapes [54] (Figure 2.4) : (1) pré-traitement ; (2) génération d'une image différentielle (DI) ; (3) analyse du DI pour obtenir des pixels modifiés et inchangés.




Figure 2. 4: Cadre général de la détection de changements par analyse post-comparaison

2.2.4 Évaluation des performances

L'évaluation de la précision dans le domaine de la télédétection comporte une évaluation qualitative et quantitative, qui consiste à examiner brièvement l'ensemble du processus de détection de changements, qui peut servir à illustrer la performance du modèle de détection de changements [55]. Pour évaluer les résultats liés à la détection de changements, une évaluation rapide basée sur la matrice d'erreur est couramment utilisée.

La détection de changements est exprimée par une carte binaire où les régions modifiées sont affichées en pixels blancs et les régions inchangées en pixels sombres. Les mesures de performance largement utilisées sont la précision globale, le taux de fausses alarmes, le taux d'alarmes manquées et le taux d'erreur total [56], [57]. Le coefficient kappa [58] est un autre indicateur précieux qui évalue la compétence des algorithmes de détection de changement.

2.3 Détection de changements en imagerie SAR post-comparaison : Travaux connexe

La technologie de détection de changements dans les images SAR s'est bien développée, cependant, avec l'augmentation des canaux d'acquisition de données et la portée des applications, les algorithmes impliqués ne peuvent pas répondre aux exigences d'une plus grande précision et d'une plus grande flexibilité des applications.

Actuellement, les méthodes post-comparaison sont la norme avec un rendement supérieur, plusieurs problèmes entravent leurs performances telles que :

1. **Le bruit de chatoiement** : À titre de caractéristique importante des images SAR, le bruit rend les détails de l'image flous et réduit l'intensité et la résolution spatiale de images, rendant difficile l'interprétation des images SAR.

Lorsque l'information éditée est extraite, la présence de speckle se traduit par quelques fausses alarmes. Il en résulte que la suppression du bruit est une étape régulière avant la détection. De nombreux algorithmes ont été développés pour résoudre ce problème.

2. **La génération de DI** : l'image de différence exerce une grande influence sur les performances de la détection, en même temps, des informations modifiées risquent d'être perdus lors de sa génération. Une bonne DI est un prérequis pour une détection correcte.

3. Une méthode de classification efficace ? Il s'agit de l'étape la plus cruciale dans l'ensemble de l'algorithme, qui détermine les résultats ultimes de détection de changements.

Ces méthodes peuvent être classées en deux grandes catégories : les méthodes supervisées et les méthodes non supervisées.

Bien que les méthodes supervisées aient tendance à donner de meilleurs résultats que les méthodes non supervisées, elles nécessitent des informations préalables pour former le classificateur, généralement obtenue par étiquetage manuel qui nécessite beaucoup de travail, ce qui représente une tâche délicate et coûteuse. Ainsi, les approches non supervisées, où l'information préalable de l'ensemble de formation n'est pas nécessaire, sont devenues attrayantes pour les tâches de détection de changements, en raison de leurs caractéristiques auto-organisatrices, généralisables et tolérantes aux pannes.

La section suivante couvre la revue de la littérature sur la détection de changements en imagerie SAR basée sur les méthodes post-comparaison mises en œuvre avec ses enjeux et ses défis.

2.3.1 Génération de l'image de différence (DI)

Dans l'étape de génération de DI, la méthode du rapport [59] est la technique courante, toutefois, elle ne tient pas en compte les informations locales de bord et d'autres informations préalables de l'image. D'autres méthodes améliorées reposant sur l'opérateur de rapport ont été proposées, y compris l'opérateur de rapport logarithmique (LR) [60], l'opérateur de rapport basé sur le voisinage (NR) [61] et l'opérateur de rapport moyen (MR) [62].

L'opérateur de rapport logarithmique convertit les valeurs des pixels des images en une dimension logarithmique, puis le rapport des deux images est calculé [63], alors que, l'opérateur de rapport moyen intègre les pixels voisins locaux et calcule le rapport de valeur moyenne pour les deux images .

Une image de différence obtenu via un seul opérateur peut ne pas être suffisante pour l'analyse séquentielle, par conséquent, la combinaison de différents opérateurs est utilisée. Par exemple, dans [64] la fusion d'ondelettes d'images de rapport moyen et de rapport logarithmique est appliquée pour générer DI.

Une stratégie de fusion d'images reposant sur le rapport logarithmique gaussien et l'image logarithmique a été adoptée dans [1]. Gong et al. [61] ont proposé un opérateur de rapport basé sur le voisinage pour combiner les informations spatiales et les informations de niveau de gris,

qui a produit des résultats supérieurs à ceux des méthodes traditionnelles. Dans [58], les auteurs ont proposé un rapport basé sur le quartier adaptatif spatio-temporel pour sélectionner la taille de fenêtre optimale pour résoudre le problème de la fenêtre rectangulaire de taille fixe. En outre, un test de rapport de vraisemblance généralisé adaptatif (AGLRT) a été développée pour atténuer la dégradation géométrique du DI causée par l'intégration de pixels hétérogènes [65]. Récemment, une méthode de génération de DI a été suggérée dans [66] en utilisant des informations spatiales irrégulières, dans laquelle les limites et les textures claires ont été préservées en faisant correspondre les hypergraphes.

2.3.2 Analyse de l'image de différence (DI)

L'analyse DI est une étape critique, par laquelle la détection de changements est convertie en une tâche de classification binaire. Les méthodes de seuillage et de regroupement (clustering) sont deux méthodes conventionnelles utilisées. Récemment, un nouveau champ de recherche basé sur des approches d'apprentissage automatique a acquis un rôle très central dans le domaine de la compréhension des images. De nombreuses nouvelles approches ont été développées, ou des réseaux de neurones profonds ont été intégrés dans des modèles traditionnels de classification de DI.

2.3.2.1 Méthodes de seuillage

Ces méthodes peuvent être réalisées soit dans une procédure manuelle d'essais et d'erreurs (selon le compromis souhaité entre les fausses alarmes et les alarmes manquées) ou par des techniques automatiques (par exemple, en fixant la probabilité de fausse alarme souhaitée [67], [68], ou en suivant une règle de décision d'erreur minimum bayésienne [43] [54]).

Ces méthodes de seuillage ont atteint de bonnes performances lorsque les classes modifiées et inchangées ont des modes distincts dans l'histogramme de DI, respectivement. Cependant, ils rencontrent souvent des difficultés lorsque les classes modifiées et inchangées se chevauchent fortement ou que leur distribution statistique ne peut pas être modélisée avec précision [69].

2.3.2.2 Méthodes de regroupement (clustering)

Les méthodes de regroupement ont été proposées pour prendre en compte les informations régionales locales, y compris principalement le clustering K-means [70] et le clustering flou c-means (FCM) [71].

Celik [72] a proposé une méthode efficace de détection de changements en utilisant le regroupement PCA et k-means. Dans cette méthode, l'image de différence est divisée en blocs d'images qui se chevauchent. Un espace vectoriel caractéristique est créé en projetant le bloc autour de chaque pixel dans l'espace du vecteur propre, puis l'algorithme de clustering k-means est employé pour regrouper l'espace vectoriel caractéristique en classes modifiées et inchangées.

L'autre algorithme est le FCM plus répandu que le clustering K-means dans la détection de changements d'image SAR, plusieurs variantes de FCM ont été proposées pour réduire le bruit de speckle tout en conservant les détails spatiaux. Gong et al. [49] ont reformulé le FLICM (RFLICM) en utilisant le coefficient de variation pour remplacer la distance euclidienne. L'algorithme proposé n'a pas besoin d'estimer la répartition des classes modifiées et inchangées et il est robuste au bruit de chatoiement car il utilise des informations locales.

Li et al. [73] ont proposé une nouvelle méthode de détection de changements basée sur le clustering à deux niveaux. Le clustering à deux niveaux est conçu dans l'espace des caractéristiques de Gabor en combinant successivement le clustering fuzzy c-means (FCM) de premier niveau avec la règle du voisin le plus proche du second niveau. Tian et Gong [74] ont proposé un FCM pondéré par les bords en introduisant un lissage par morceaux avant d'équilibrer le compromis entre la réduction du bruit et la préservation des bords.

Li et al. [75] ont développé un algorithme FCM spatial (SFCM) avec une fonction spatiale ajoutée à l'appartenance floue pour la suppression du bruit.

2.3.2.3 Méthodes basées sur l'apprentissage en profondeur

Avec l'augmentation du nombre et de la diversité des données, la faible expressivité des caractéristiques extraites par les méthodes traditionnelles réduit significativement la précision de détection de changements, bien que certaines de ces méthodes permettent de réduire les faux changements en combinant des caractéristiques de forme et de texture, mais cela exige du temps et c'est fastidieux. En outre, les caractéristiques artisanales s'appuient fortement sur les connaissances propres au domaine, ce qui réduit la capacité d'automatisation de la technologie de détection des changements.

En général, les méthodes traditionnelles qui exigent des connaissances spécialisées sont généralement sous-optimales et le caractère empirique de la représentation des images est faible.

Une nouvelle ligne de recherche émergente reposant sur des approches d'apprentissage automatique (Machine Learning), a acquis un rôle très central dans la détection de changements, actuellement considéré comme l'ensemble des approches les plus prometteuses et les plus évolutives [76], en raison de leur capacité à surpasser les méthodes traditionnelles, offrant une meilleure compréhension des scènes complexes. L'adoption de telles méthodes est principalement motivée par la disponibilité sans précédent de nouveaux capteurs de télédétection avancés, capables de recueillir un large éventail de données, permettant de détecter des informations avec une précision et une résolution temporelles/spatiales inégalées.

L'apprentissage en profondeur a attiré une grande attention dans le domaine de la compréhension des images, grâce à sa capacité à apprendre automatiquement des caractéristiques sémantiques et contextuelles de haut niveau, il a généré une excellente performance et un taux de précision de classification plus élevé que les approches traditionnelles.

Pour améliorer les performances de l'analyse de DI, des réseaux de neurones profonds ont été intégrés dans des modèles traditionnels de classification DI. Des modèles profonds comprennent les Réseaux de Croyances Profondes (RBN) [77], les Réseaux de Neurones Récurents [78], les Réseaux de Neurones Convolutionnels (CNN) [79] et auto-encodeurs empilés (SAEs) [80].

Hou et al. [81] ont proposé une méthode de détection de changements basé sur des réseaux de neurones convolutionnels multiniveaux (CNN). La détection est obtenue en détectant les régions saillantes des images de caractéristiques de différence en utilisant d'une décomposition de rang inférieur.

Dans [82], l'apprentissage profond transféré a été appliqué à la détection de changement d'image SAR de glace de mer basée sur CNN. Dans [83] une couche de mise en commun contrainte par les ondelettes est conçue pour remplacer la mise en commun conventionnelle dans CNN. L'architecture CWNN est capable de supprimer le bruit de speckle et mieux conserver les structures des caractéristiques apprises.

Chen et al. [84] ont présenté un réseau neuronal récurrent multicouche siamois profond (RNN) pour la détection des changements. RNN à plusieurs couches a été conçu pour gérer les fonctionnalités extraites par CNN, qui a cartographié les fonctionnalités dans un nouvel espace.

Dans [76] sparse autoencoder, un Réseau Neuronal Convolutif (CNN) et clustering non supervisé sont combinés pour apprendre des représentations de différence robustes pour la détection de changement.

Zhan et al. [85] ont proposé un réseau profond entièrement convolutif (FCN) bien pré-entraîné pour extraire automatiquement les informations de contexte spatial profond à partir des images acquises. Et sur cette base, une segmentation superpixel multi-échelle a été utilisée pour générer une carte de changement binaire robuste avec une précision de détection élevée.

Samadi et al [86] ont utilisé un Réseau de Croyance Profond (Deep Belief Network - DBN) comme architecture profonde. Le processus de formation de ce réseau comprenait un apprentissage non supervisé des fonctionnalités suivi d'un réglage fin du réseau supervisé. Les performances de la détection ont été grandement améliorées par rapport aux méthodes clustering traditionnelles.

Dans [87] des auto-encodeurs contractuels supervisés (SCAE) combinés au clustering FCM ont été développés pour la détection de changements d'image SAR, où les caractéristiques de pixel de voisinage des deux images SAR originales et DI sont connectées en tant qu'entrée de SCAE.

Les méthodes existantes de détection de changements basées sur l'apprentissage en profondeur ont obtenu un grand succès dans le domaine de la reconnaissance d'images, mais nécessitent une grande quantité d'échantillons d'apprentissage pour optimiser les paramètres du réseau. Lorsque les données de formation sont insuffisantes ou ne sont pas équilibrées dans toutes les classes, l'augmentation des données est généralement adoptée pour résoudre le problème. Les techniques d'augmentation courantes incluent les transformations affines telles que la rotation, la translation et la mise à l'échelle, ainsi que la stratégie de combinaison linéaire [88] [89] .

Des approches de pré-classification ont été proposées afin d'ajouter automatiquement des informations préalables pour l'apprentissage du modèle dans les cadres non supervisés.

Gao et al. [90] ont appliqué des C-means flous (FCM) pour une pré-classification de DI, qui vise à sélectionner des pixels avec de fortes probabilités d'être modifiés et inchangés.

Plus tard, un cadre de détection de changements basé sur l'analyse du domaine fréquentiel et les multigraphes aléatoires a été proposé dans [91], où la FCM est également utilisée pour une pré-classification. Zhan et al. [92] ont développé un réseau de neurones à deux couches pour

l'identification des zones modifiées, où l'algorithme C-means d'informations locales floues est adopté pour la pré-classification.

2.4 Conclusion

Grâce à l'introduction de divers algorithmes et à des recherches approfondies menées par divers chercheurs, la technologie de détection de changements d'image SAR a fait de grands progrès.

Parallèlement, avec les avancées technologiques et l'amélioration de la qualité de l'image SAR, le champ d'application de cette technologie ne cesse d'augmenter et les attentes à l'égard de ces algorithmes se sont accrues, si bien que les algorithmes existants ont commencé à montrer leurs limites.

Dans ce chapitre, nous avons présenté un aperçu des techniques de détection de changements en imagerie SAR. Ces méthodes sont assez variées, nous avons mis en évidence le courant dominant actuel avec d'excellentes performances, il s'agit des méthodes de détection du changement basées sur la post-comparaison dont le cadre général a été systématiquement examiné et analysé, et des modèles basés sur l'apprentissage en profondeur sont présentés plus en détail.

Chapitre 3

Méthode de détection de changements basée sur un réseau de croyance profond

Le présent chapitre est une adaptation de l'article paru sous le titre :

S. Attioui, S. Najah: Unsupervised change detection method in SAR images based on deep belief network using an improved fuzzy C-means clustering algorithm. IET Image Processing, 15 (4) (2021), pp. 974-982.

Il présente un nouveau cadre dans lequel le problème de détection de changements est résolu d'une manière non supervisée. Une approche de détection de changements spécialement conçue pour analyser les images radar à synthèse d'ouverture basée sur un réseau de croyance profond en tant qu'architecture profonde qui inclut l'apprentissage non supervisé des fonctionnalités et le réglage fin du réseau supervisé. Les réseaux de neurones profonds peuvent atteindre les cartes de changement finales directement à partir des deux images originales. Une pré-classification basée sur la reconstruction morphologique et le filtrage des membres est utilisée afin de minimiser l'effet du bruit. Des études sur les réseaux de croyances profonds démontrent qu'ils ne produisent pas de sortie idéale sans un ensemble de données approprié pour la formation, par conséquent, des échantillons de diversité appropriés sont fournis par un procédé de génération d'échantillons virtuels afin d'atténuer le surajustement provoqué par des données radar à ouverture synthétique limitée. Les résultats expérimentaux ont indiqué que la méthode proposée obtient non seulement de meilleurs résultats mais nécessite également moins de temps de mise en œuvre.

3.1 Introduction

L'évolution rapide des capteurs et des technologies informatiques a fait apparaître de nouveaux défis dans l'analyse et l'interprétation des images numériques. Dans le domaine de l'électronique, les techniques de traitement d'image et de vision industrielle peuvent aider à identifier et mesurer différentes cibles dans une image afin d'extraire des informations utiles en

fonction de besoins spécifiques. Des applications importantes dans plusieurs domaines ont vu le jour là où les techniques de vision industrielle chevauchent les techniques de traitement d'image, notamment la vidéosurveillance, la télédétection, le diagnostic médical, l'armée et la détection des changements.

La détection de changements est une technologie clé qui vise à identifier tout changement dans la même scène acquise à des moments différents. Elle reste l'un des sujets de recherche les plus cruciaux et les plus distingués dans le domaine de la télédétection, en raison de son utilisation largement répandue dans de nombreuses applications d'observation de la Terre, y compris la planification urbaine [93], l'enquête agricole et la surveillance des catastrophes [1].

Le radar à synthèse d'ouverture (SAR) est devenu une puissante technologie de télédétection grâce à sa capacité à observer la surface de la Terre à tout moment et dans toutes les conditions météorologiques [2]. Les progrès récents dans les technologies d'acquisition d'imagerie SAR ont considérablement augmenté le potentiel de surveillance SAR, de nombreuses images sont disponibles couvrant une vaste zone avec un bref temps de révision. Cependant, à cause des difficultés causées par la présence de bruit de chatoiement qui entrave l'interprétation des données SAR et dégrade les performances de détection de changements, la détection de changements dans les images SAR est un problème plus difficile que l'imagerie optique par satellite, de meilleures méthodes deviennent nécessaires.

Généralement, les méthodes de détection de changements suivent l'une des deux approches, la comparaison post-classification [94] ou l'analyse post-classification [95].

Dans la première approche, la carte de changements est identifiée en comparant des cartes de classification dérivées indépendamment des deux images SAR de la même zone à des moments temporels différents. Cette méthode a l'avantage d'acquérir de plus grandes informations sur les catégories qui ont changé et d'empêcher également la normalisation du rayonnement des images de télédétection, réduisant ainsi l'impact externe des différences atmosphériques sensorielles et environnementales entre les images de télédétection multi-temporelles. Cependant, une exigence de haute précision pour la classification de chacune des deux images est requise.

Contrairement à la détection de changements qui nécessite une comparaison sur des pixels précédemment classifiés, l'analyse post-classification est l'une des méthodes les plus avancées et les plus couramment utilisées, principalement basée sur une image de différence (DI) générée via une analyse comparative des deux images multi-temporelles contaminées par le bruit.

Cependant, la validité des résultats de détection de changements dépend de la qualité de DI générée qui devrait prendre en compte le problème de la suppression du bruit.

Dans la phase de génération de DI, les opérateurs de rapport sont généralement les techniques les plus largement utilisées, tels que l'opérateur de rapport moyen et l'opérateur de rapport logarithmique [63] considéré robuste au bruit de speckle, ayant la capacité de transformer le bruit multiplicatif en bruit additif. Gong et coll. [61] ont proposé un opérateur de rapport basé sur le voisinage pour acquérir l'image de différence en combinant des informations spatiales et des informations de niveau de gris.

Dans l'étape d'analyse de l'image DI, les pixels sont alors classés en classes modifiées et inchangées. Deux méthodes conventionnelles ont été largement utilisées, à savoir les méthodes de seuillage et les méthodes de regroupement.

Dans les méthodes de seuillage, la méthode Ostu [96] et l'algorithme de seuil minimum de Kittler – Illingworth (KI) [59] ont été appliqués pour déterminer le seuil optimal. Pour trouver automatiquement ce seuil optimal qui minimise la probabilité d'erreur totale dans le processus de détection de changements, plusieurs méthodes ont été proposées, dont celles de, Bruzzone et al. [97] qui ont proposé une méthode de seuil dans laquelle l'image de différence a été modélisée par une distribution gaussienne, l'algorithme Expectation-Maximization (EM) a été aussi utilisé pour déterminer un seuil optimal. Xiong et coll. [98] ont penché sur la question du choix du seuil en combinant les caractéristiques de deux mesures de détection de changements par une approche markovienne.

Ces approches discriminaient les régions modifiées et inchangées en supposant que chaque classe a un mode distinct dans l'histogramme de l'image DI. Par conséquent, ils sont souvent confrontés à des difficultés lorsque l'image DI présente un histogramme unimodal.

Pour éviter les inconvénients des approches de seuillage, des algorithmes de clustering sont utilisés pour ajuster les modèles de classes modifiées et inchangées, et davantage de recherches se sont consacrées au développement de classificateurs puissants. Parmi les méthodes de clustering les plus populaires, nous trouvons l'algorithme Fuzzy C-Means (FCM).

Bien que les algorithmes traditionnels de détection de changements basée sur les pixels mentionnés ci-dessus soient simples et rapides, leur précision peut être altérée en raison des caractéristiques de classification comparables limitées du pixel. Il s'ensuit que le problème s'aggrave lorsque le bruit dans l'image est présent.

Pour dépasser les limites des techniques traditionnelles, de nombreuses approches ont été proposées visant à interpréter statistiquement l'évolution des pixels par un moyen de modéliser la texture locale et les relations contextuelles. Une série de classificateurs a été utilisée par des approches utilisant des modèles discriminants, tels que la machine à vecteurs de support (SVM) [99], la classification basée sur la représentation de rechange (SRC) [100], le réseau neuronal (NN) [101] et forêts aléatoires (RF) [102] .

Les méthodes d'extraction de caractéristiques jouent un rôle clé dans la performance de ces classificateurs, de nombreuses méthodes pour extraire les caractéristiques spatiales basées sur des descripteurs de texture ont été proposées pour les images SAR, notamment, dans l'analyse statistique : deux méthodes ont été utilisées, l'énergie d'ondelette de kurtosis (KWE) et l'énergie de curvelet de kurtosis (KCE) [103] [104]. À noter que KCE est plus efficace comme dispositif de discrimination de texture. Dans l'analyse du domaine de transformation, la transformation en ondelettes et le filtre de Gabor sont largement utilisés pour extraire les caractéristiques des images SAR. Pour l'analyse basée sur un modèle, les modèles de champ aléatoire de Markov (MRF) sont les plus largement utilisés, fournissent un modèle stochastique efficace et pratique pour incorporer des informations contextuelles spatiales dans le processus de classification.

Tous les algorithmes de classification mentionnés ci-dessus nécessitent de l'ingéniosité et des connaissances préalables, de plus, ils n'ont pas atteint les performances promises. Ces dernières années, beaucoup de recherches ont porté sur le développement de classificateurs performants, tels que le modèle de régression linéaire généralisée [105], la méthode POLWHE [106] et l'hybride MLPNN-ICA [107] .

Récemment, l'apprentissage profond a gagné en popularité grâce aux résultats encourageants pour de nombreux problèmes, à savoir la reconnaissance vocale [108], la reconnaissance d'images [109], et la classification [110] [111].

L'apprentissage en profondeur est un nouvel horizon, capable d'extraire des traits discriminants. Différents types d'architectures d'apprentissage en profondeur existent, tels que le réseau de neurones profonds (DNN), le réseau de neurones convolutifs (CNN), le réseau de croyances profondes (DBN) et les réseaux de croyances profondes convolutives (CDBN).

L'apprentissage en profondeur a été largement appliqué au traitement d'images SAR, un grand nombre de techniques ont été proposées. Par exemple, Gong et al. [112] ont proposé une méthode de détection de changements dans l'imagerie SAR basée sur l'apprentissage profond, la carte de détection de changements finale est établie directement à partir des images SAR originales sans

qu'il soit nécessaire de générer une image de différence. Selon les premiers résultats obtenus par FCM, un ensemble d'apprentissage est conçu en prenant des blocs avec des fenêtres coulissantes sur les deux images originales, puis un réseau neuronal profond utilisé pour apprendre les caractéristiques d'ordre élevé et pour classer les images SAR.

Motivée par l'idée d'utiliser DBN pour résoudre le problème de détection de changements, une approche similaire dans [86] vise à améliorer la formation du DBN en augmentant la quantité de données appropriées en utilisant les images d'entrée et les images acquises en leur appliquant des opérateurs morphologiques. Hou et coll. [81] ont présenté une technique de de détection de changements basée sur des caractéristiques du réseau neuronal convolutif à plusieurs niveaux (CNN), la détection de changements est obtenue en détectant les régions saillantes des images de caractéristiques de différence à l'aide d'une décomposition de rang inférieur. Sharifzadeh et coll. [113] ont développé un algorithme hybride basé sur un réseau neuronal convolutif et un perceptron multicouche (CNN – MLP) pour la classification des images, avec des performances améliorées. Wang et coll. [114] ont proposé un cadre de détection de changements pour les images de télédétection hyper-spectrales basé sur le réseau de neurones convolutifs 2D de bout en bout (GETNET) dans lequel la matrice d'affinité mixte qui intègre la représentation sous-pixel est utilisée pour extraire les caractéristiques discriminantes.

À la lumière de ce qui précède, bien que diverses méthodes aient montré des résultats impressionnants et prometteurs, plusieurs obstacles entravent les performances de la détection de changement d'image SAR, tels que le calcul coûteux, le temps de traitement, la présence de bruit de chatoiement qui rend l'interprétation des images SAR très difficile et peut conduire à certaines fausses alarmes lors de l'extraction d'informations modifiées, une forte dépendance vis-à-vis des hypothèses utilisées dans la modélisation de l'image de la différence, ce qui a une incidence directe sur la performance de détection du changements, la difficulté de produire des données étiquetées, enfin, les réseaux profonds existants utilisés sont susceptibles de générer de nombreuses fonctions redondantes qui affectent les performances du réseau.

La méthode proposée dans ce chapitre, vise à améliorer les résultats de la méthode de détection de changements SAR basée sur des architectures profondes. Ces principaux apports sont doubles, d'une part, un schéma de génération d'échantillons virtuels est utilisé pour mieux former le réseau en augmentant les échantillons de diversité appropriés et le problème d'échantillons limités est allégé, tandis que d'autre part, il vise à réduire l'impact de la présence de speckle ainsi que le temps de traitement.

3.2 Préliminaires méthodologiques

3.2.1 Algorithme FRFCM (C-moyens flous Rapide et Robuste)

Bien que l'algorithme des c-moyens flous (FCM) ait attiré beaucoup d'attention depuis sa création [115] [116], il présente de sérieuses lacunes, notamment sa non-robustesse aux images avec une texture complexe et un fond corrompu en raison du bruit, car il traite un seul pixel sans incorporer les informations spatiales.

Pour faire face à ses défis, plusieurs approches ont été proposées : la première amélioration concerne l'incorporation d'informations spatiales dans une fonction objective. Certains algorithmes classiques liés au FCM, tels que FCM_S [117], FCM_S1, FCM_S2 [118], EnFCM [119] et FGFCM [120], ont été suggérés. Principalement, Krinidis et Chatzis [121] ont présenté un nouvel algorithme de regroupement robuste d'informations locales floues (FLICM) qui intègre un nouveau facteur flou dans sa fonction objective visant à garantir l'immunité au bruit et la préservation des détails de l'image. Bien que l'algorithme FILCM s'est révélé plus performant que les algorithmes précédents, son inconvénient vient de la distance euclidienne non robuste adoptée qui n'est pas efficace pour les informations spatiales arbitraires des images. Une deuxième amélioration vise à surmonter le problème en introduisant des distances de noyau robustes dans la fonction objectif, qui s'est traduit par une série d'algorithmes FCM basés sur le noyau tels que : KWFLICM [122], ARKFCM [123], KGFCM [124], NDFCM [125]. Par exemple, Zhao et al. [126] ont rapporté un algorithme de regroupement des moyennes floues pondérées par voisinage (NWFCM) qui remplace la distance euclidienne habituelle dans la fonction objective de FCM par une distance pondérée de voisinage.

Récemment, Lei et al. [127] ont proposé un nouvel algorithme basé sur la reconstruction morphologique et le filtrage d'appartenance visant à obtenir le meilleur compromis entre la préservation des détails et la suppression du bruit.

Étant donné $f = \{x_1, x_2, \dots, x_N\}$ qui représente une image en niveaux de gris, x_i est la valeur de gris du $i^{\text{ème}}$ pixel, N est le nombre total de pixels de l'image f .

FRFCM Clustering (Fast and robust fuzzy C-means) est réalisé sur l'histogramme des niveaux de gris d'une image reconstruite par la reconstruction morphologique (RM). L'introduction de l'histogramme permet de réduire la complexité de calcul de FCM.

La reconstruction morphologique (RM) a été introduite avant d'appliquer le clustering afin d'optimiser une caractéristique de distribution des données. Meilleure que beaucoup d'opérations

de filtrage usuelles, la reconstruction morphologique est en mesure de préserver les détails de l'image et d'éliminer le bruit sans aucune connaissance préalable du type de bruit.

D'une manière générale, la reconstruction morphologique comprend deux opérations de base, à savoir les reconstructions par dilatation et par érosion [128]. Sur la base de leur combinaison, l'ouverture et la fermeture de deux opérations morphologiques sont obtenues. Étant donné que la fermeture morphologique est plus applicable pour le lissage des détails de texture, nous l'avons utilisé pour modifier l'image originale.

La fonction objective est définie comme suit :

$$J_m = \sum_{l=1}^q \sum_{k=1}^c \gamma_l \mu_{kl}^m \|\xi_l - v_k\|^2 \quad (3.1)$$

Où $1 \leq l \leq q$, q (généralement beaucoup plus petit que N) est le nombre de niveaux de gris contenus dans ξ qui est une image reconstruite par une reconstruction morphologique de fermeture définie comme :

$$\xi = R^C(f) \quad (3.2)$$

Où R^C désigne la reconstruction de fermeture morphologique.

$$R^C(f) = R_{R_f^D(\varepsilon(f))}^\varepsilon \left(D \left(R_f^D(\varepsilon(f)) \right) \right) \quad (3.3)$$

$$R_f^D(g) = D_f^{(t)}(g) \quad (3.4)$$

$$R_f^\varepsilon(g) = \varepsilon_f^{(t)}(g) \quad (3.5)$$

$R_f^D(g)$ dénote la reconstruction par érosion

$R_f^\varepsilon(g)$ désigne la reconstruction par dilatation

g image de marqueur

D et ε sont réalisés en utilisant un élément structurant plat. μ_{kl} représente l'appartenance floue de la valeur de gris l par rapport au $k^{\text{ième}}$ cluster. m est un exposant de pondération, γ_l est le nombre de pixels dont le niveau de rayon est égal à ξ , et v_k désigne la valeur prototype du $k^{\text{ième}}$ clustering.

$$\sum_{l=1}^q \gamma_l = 1 \quad (3.6)$$

On a besoin de trouver les valeurs des paramètres pour lesquels la fonction objective a la valeur minimum.

Le problème de la minimisation est résolu par la technique du multiplicateur de Lagrange qui peut convertir le problème en un problème sans contrainte. Le multiplicateur de Lagrange (λ) est utilisé pour trouver le point - selle de la fonction de Lagrange suivante :

$$J_m = \sum_{l=1}^q \sum_{k=1}^c \gamma_l \mu_{kl}^m \|\xi_l - v_k\|^2 - \lambda \left(\sum_{k=1}^c \mu_{kl} - 1 \right) \quad (3.7)$$

La fonction d'appartenance et les centres de cluster sont obtenus en minimisant la fonction objectif (1).

Sous réserve de $\sum_{k=1}^c \mu_{ki} = 1$ pour chaque pixel x_i

$$\mu_{kl} = \frac{\|\xi_l - v_k\|^{-2/(m-1)}}{\sum_{j=1}^c \|\xi_l - v_j\|^{-2/(m-1)}} \quad (3.8)$$

$$v_k = \frac{\sum_{l=1}^q \gamma_l \mu_{kl}^m \xi_l}{\sum_{l=1}^q \gamma_l \mu_{kl}^m} \quad (3.9)$$

Selon (8), une matrice de partition d'appartenance $U = [\mu_{kl}]^{c \times q}$ est obtenue. Le processus itératif se termine lorsque $\max\{U^{(t)} - U^{(t+1)}\} < \eta$, η est le seuil d'erreur minimal.

L'introduction des informations spatiales locales est similaire au filtre d'appartenance qui ne nécessite pas de calculer la distance entre les pixels au sein des voisins spatiaux locaux, ce qui se traduit par une accélération de la convergence de notre algorithme. Nous utilisons un filtre médian.

$$U' = \text{med}\{U\} \quad (3.10)$$

À partir de l'analyse ci-dessus, l'algorithme FRFCM proposé peut être résumé de la façon suivante :

- **Étape 1** : Définissez la valeur du prototype de cluster c , le paramètre de fuzzification m , la taille de la fenêtre de filtrage w et le seuil d'erreur minimal η .
- **Étape 2** : Calculez la nouvelle image ξ en utilisant (2), puis calculez son histogramme.
- **Étape 3** : Initialiser aléatoirement la matrice de partition d'appartenance $U(0)$.
- **Étape 4** : Régler le compteur de boucle $t=0$.

- **Étape 5** : Mettez à jour les centres de clustering à l'aide de (9).
- **Étape 6** : Mettre à jour la matrice de partition d'appartenance $U(t+1)$ à l'aide de (8).
- **Étape 7** : Si $\max \{U(t) - U(t+1)\} < \eta$ alors arrêtez, sinon, fixez $t=t+1$ et passez à l'étape 5.
- **Étape 8** : Appliquer le filtrage médian sur la matrice de partition d'appartenance U' en utilisant (10).

3.2.2 Les réseaux de neurones profonds

Inspiré par la profondeur architecturale du cerveau et s'appuyant sur la connaissance des statistiques et des mathématiques appliquées, l'apprentissage en profondeur est devenu un nouveau type de méthode d'apprentissage automatique et a fait l'objet d'une attention accrue au cours des dernières années. Cette approche performante permet d'atteindre la flexibilité et l'évolutivité en représentant le monde en tant que structure hiérarchique intégrée de concepts.

La présente section examine le DBN utilisé dans l'algorithme proposé et ses composants RBM.

3.2.2.1 Introduction à la machine de Boltzmann restreintes RBM

La machine Boltzmann restreinte RBM « Restricted Boltzmann machine » est un réseau à deux couches avec des unités de traitement stochastiques connectées de manière bidirectionnelle, une structure ordinaire du réseau RBM est illustrée à la Figure 3.1.

Les unités V de la première couche, notées par le vecteur $V = (v_1, v_2 \dots v_n)$ correspondent aux composantes d'une observation et sont donc dites « visibles », tandis que les unités H de la seconde couche $H = (h_1, h_2 \dots h_m)$ représentent les variables latentes, et sont dites « cachées ».

Où m et n représentent le nombre d'unités. La couche visible est en entrée et la couche cachée est située en sortie.




Figure 3. 1: Architecture de la Machine de Boltzmann restreintes RBM

Une paire de nœuds à partir de chacun des deux groupes d'unités (visibles et cachés respectivement) peuvent avoir une connexion symétrique entre eux, par le biais d'un ensemble de poids w_{ij} et les biais $\{b_i, c_j\}$, et il n'existe aucune connexion entre les unités de la même couche.

$W = \{w_{ij} \mid 1 \leq i \leq n, 1 \leq j \leq m\}$ représente une matrice de poids des connexions entre la couche visible et la couche cachée.

$b = (b_1, b_2, \dots, b_n)$ sont des biais d'unités visibles, $c = (c_1, c_2, \dots, c_m)$ sont des biais d'unités cachées.

Dans une RBM classique, une configuration conjointe (V, H) des unités visibles et cachées est caractérisée par une énergie donnée par :

$$E(V, H) = - \sum_{i=1}^n b_i v_i - \sum_{j=1}^m c_j h_j - \sum_{ij} v_i h_j w_{ij} \quad (3.11)$$

La RBM attribue une probabilité à chaque configuration (V, H) , déterminée par la fonction d'énergie :

$$p(V, H) = \frac{1}{Z} \exp[-E(V, H)] \quad (3.12)$$

La constante de normalisation Z est appelée la fonction de partition, est calculé par la somme de tous les modes possibles entre les couches visibles et cachées et garantit également que la somme de toutes les probabilités sera égale à 1.

$$Z = \sum_{V, H} \exp[-E(V, H)] \quad (3.13)$$

La somme de tous les états possibles de la couche cachée peut être utilisée pour obtenir la probabilité de l'état de la couche visible :

$$p(V) = \sum_H p(V, H) \quad (3.14)$$

Supposons que $\forall i, j, v_i \in \{0, 1\}, h_j \in \{0, 1\}$, et étant donné le vecteur d'entrée V , il s'ensuit que l'état binaire de chaque unité cachée h_j , est défini sur 1 avec la probabilité :

$$p(h_j = 1|V) = \sigma \left(\sum_{i=1}^n w_{ij} \times v_i + c_j \right) \quad (3.15)$$

Où $\sigma(x) = 1/(1 + e^{-x})$ est une fonction sigmoïde logistique.

Une fois que les états binaires ont été choisis pour les unités cachées, des données reconstructives sont produites en mettant chaque v_i à 1 avec la probabilité :

$$p(v_i = 1|H) = \sigma \left(\sum_{j=1}^m w_{ij} \times h_j + b_i \right) \quad (3.16)$$

Les états des unités cachées sont alors mis à jour une fois de plus de sorte qu'ils représentent les caractéristiques des données de reconstruction.

La règle des modifications de poids dans le logarithme de probabilité pour les données d'apprentissage peut être déterminée comme suit :

$$\Delta W_{ij} = \varepsilon (\langle v_i h_j \rangle_{\text{données}} - \langle v_i h_j \rangle_{\text{modèle}}) \quad (3.17)$$

Où ε est le taux d'apprentissage, $\langle \rangle$ représente l'espérance sous la distribution indiquée par l'indice qui suit.

Les états du modèle $\langle v_i h_j \rangle_{\text{modèle}}$ sont difficiles à obtenir, l'échantillonnage de Gibbs est particulièrement utile dans ce cas. L'idée de l'échantillonnage de Gibbs est d'utiliser la distribution conditionnelle de chaque variable impliquée et d'échantillonner progressivement chaque variable, en fonction de toutes les autres variables. L'échantillonnage de Gibbs est par définition une méthode Monte Carlo de chaîne de Markov.

L'algorithme général de l'échantillonneur est un processus itératif qui peut être décrit avec les étapes suivantes : nous partons d'une valeur aléatoire en unités visibles et effectuons les étapes d'échantillonnage de Gibbs pendant une longue période. Une étape d'échantillonnage de Gibbs équivaut à mettre à jour toutes les unités cachées concernant (15) puis à mettre à jour toutes les unités visibles par (16). (Figure 3.2).




Figure 3. 2: Visualisation de la manière dont Gibbs procède à l'échantillonnage par couche dans RBM

Cependant, à mesure que le nombre de neurones dans RBM augmente, un plus grand nombre d'échantillons doit être recueilli par l'échantillonnage de Gibbs afin d'expliquer correctement la distribution de probabilité représentée par RBM. En outre, en raison de la nature des échantillonnages de Gibbs, les échantillons peuvent encore manquer certains modes de distribution. De nombreuses approches ont été proposées pour surmonter ces difficultés.

Une approche populaire est l'apprentissage par divergence contrastive (CD) proposé par Hinton (2002) comme méthode approximative [129]. L'algorithme est lancé à partir d'un échantillon d'apprentissage, v_0 , pour les états visibles dans une RBM. Itérativement pour t étapes, l'état binaire des couches cachées est calculé selon (15). Ensuite, v_{i+1} est échantillonné à partir de la distribution conditionnelle (16). Finalement, la probabilité d'activation des unités cachées est recalculée et la valeur du modèle $\langle v_i h_j \rangle_{\text{modèle}}$ est déterminée en fonction des valeurs finales obtenues des unités cachées et visibles.

3.2.2.2 Introduction au réseau de croyances profondes (DBN)

Le réseau de croyances profondes DBN « Deep Belief Networks », est un modèle génératif puissant qui utilise une architecture profonde, contrairement à RBM qui est un réseau peu profond. Le DBN est un modèle probabiliste formé d'une couche d'entrée d'observations, d'une couche de sortie de reconstructions des données d'entrée et de plusieurs couches cachées. Les unités de chaque couche cachée visent à apprendre la représentation caractéristique des données d'entrée (observation) à différents niveaux abstraits [130].

L'un des éléments clés du réseau de croyances profondes (DBN) est que chaque paire de couches adjacentes est traitée comme une machine de Boltzmann restreinte (RBM), empilées de telle manière que la sortie de la couche précédente devienne la couche d'entrée pour l'ensemble d'apprentissage suivant.

Le processus de formation de DBN se divise en deux phases : le pré-entraînement (phase non supervisée) et phase de réglage fin « fine-tuning » (phase supervisée).

Dans une première phase, le pré-entraînement tente d'approcher les paramètres avec avidité. Chaque RBM a été formée séparément, de telle sorte que la couche RBM inférieure apprend un ensemble de caractéristiques de représentation de bas niveau, puis les caractéristiques apprises sont utilisées comme entrée pour la formation d'un RBM de niveau supérieur qui devrait apprendre des caractéristiques de sujet plus complexes. Ce processus se poursuivra jusqu'à la dernière couche de RBM, il s'agit d'une phase non supervisée.

Dans la deuxième phase, le processus de réglage fin, les paramètres de toutes les couches sont affinés par la rétropropagation.




Figure 3. 3: Architecture de Réseaux de croyances profondes (3 unités cachées)

3.2.3 Échantillon virtuel

Entraîner un réseau neuronal profond qui peut bien se généraliser à de nouvelles données est un problème difficile. Le nombre d'échantillons d'entraînement disponibles est généralement limité, ce qui entraîne de mauvaises performances du réseau. Afin de résoudre ce problème, nous utilisons une méthode de génération d'échantillon virtuel qui tente d'enrichir les échantillons d'apprentissage, ce qui se traduit par une réduction du surajustement et une optimisation plus rapide du réseau.

À partir de deux échantillons donnés de la même classe, un échantillon virtuel peut être généré avec un ratio approprié.

$$\hat{P}_k = \frac{\alpha_i P_i + \alpha_j P_j}{\alpha_i + \alpha_j} + \beta \quad (3.18)$$

P_i et P_j sont deux exemples d'apprentissage de la même classe. $\hat{P}_k$ est un échantillon virtuel. Pour chaque échantillon virtuel généré α_i et α_j sont des nombres aléatoires uniformément distribués sur l'intervalle $[0, 1]$, nous attribuons la même étiquette d'échantillons d'apprentissage à l'échantillon virtuel. β est un bruit gaussien aléatoire. La moyenne de β est fixée à 0 et la variance de β est fixée à 0,001.

Dans les travaux de Chenet al. [131], une méthode similaire de génération d'échantillons virtuels a été appliquée à la classification des images hyperspectrales.

3.3 Méthodologie proposée

Considérons deux images SAR d'intensité co-enregistrées : $I_1 = \{I_1(i, j), 1 \leq i \leq M, 1 \leq j \leq N\}$, $I_2 = \{I_2(i, j), 1 \leq i \leq M, 1 \leq j \leq N\}$, de taille $M \times N$, acquises sur le même emplacement géographique à deux instants t_1 et t_2 différents, respectivement. Le but principal de la détection de changements est de générer une carte de changements, qui identifie le changement dans chaque pixel aux instants t_1 et t_2 de la scène. Cela peut être formulé comme un problème de classification où la sortie finale est une image binaire associée à des changements et des pixels inchangés. L'organigramme de la méthode proposée est illustré à la Figure 3.4, il couvre les aspects suivants : Dans une première étape, une méthode de pré-classification basée sur la reconstruction morphologique et le filtrage d'appartenance est appliquée aux images d'entrée pour générer des échantillons appropriés. La diversité des données joue un rôle important dans la formation des réseaux de neurones, certains échantillons virtuels sont également générés pour améliorer la formation de DBN. Ensuite, un DBN est conçu pour s'entraîner de manière supervisée avec des échantillons appropriés et leurs étiquettes qui sont obtenus à l'étape précédente. Dans la dernière étape, un DBN formé est utilisé pour classer chaque pixel en classes modifiées et inchangées dans la classification finale.




Figure 3. 4: Organigramme de la méthode proposée

3.3.1 Pré-classification FR Fuzzy C-Means Clustering

Afin d'éviter de générer une DI, l'algorithme proposé commence par une classification conjointe des deux images d'entrée SAR acquises sur la même région mais à des moments différents. Pour cela, nous utilisons une classification conjointe basée sur l'algorithme hiérarchique JFRFCM. Le but de cette étape est de sélectionner les pixels les mieux adaptés pour entraîner le réseau neuronal profond.

Le cœur de ce classifieur repose sur le concept de similarité entre les niveaux de gris des deux pixels aux mêmes coordonnées des deux images SAR en entrée de l'algorithme.

La matrice de similarité S_{ij} est établie à partir des deux images originales par un opérateur de similarité, $S_{ij} \in [0,1]$ défini comme suit :

$$S_{ij} = \frac{|I_{ij}^1 - I_{ij}^2|}{I_{ij}^1 + I_{ij}^2} \quad (3.19)$$

Où I_{ij} représentant les niveaux de gris relatifs à deux pixels aux positions correspondantes (i, j) .

Dans l'algorithme JFRFCM, deux valeurs de seuil de similarité T_1 et T_2 , ont été utilisé afin de définir si les deux pixels étudiés sont identiques ou ils présentent des changements l'un par rapport à l'autre.

En outre, les deux variances pondérées autour d'une moyenne pondérée, δ_{ij}^1 et δ_{ij}^2 , ont été introduites pour spécifier les pixels qui doivent être classés, nommés comme points de référence. Gong et al. [112] ont démontré qu'il est plus efficace d'utiliser le critère de variance minimale pour sélectionner les points de référence de la classification que d'utiliser la variance maximale.

Selon le principe de la variance minimale, si $\delta_{ij}^1 \leq \delta_{ij}^2$, I_{ij}^1 sera classé par l'algorithme JFRFCM. Dans l'étape suivante, l'image de similarité est comparée au seuil. L'organigramme de l'algorithme JFCM est illustré à la Figure 3.5.

Si $S_{ij} < T_1$, cela signifie qu'aucun changement n'a eu lieu $\Omega_{ij}^1 = \Omega_{ij}^2$.

Si $S_{ij} > T_2$, cela signifie qu'un changement s'est produit, le pixel de la seconde image sera classé.

Les résultats de la classification sont représentés par $\Omega = \{\Omega_u, \Omega_i, \Omega_c\}$. La classe Ω_c contient des pixels dont la probabilité de modification est élevée. Les pixels appartenant à la classe Ω_u ayant une probabilité élevée d'être inchangés. La classe Ω_i représente la classe incertaine qui sera à la fin classée par DBN.




Figure 3. 5: Organigramme de l'algorithme JFRFCM

3.3.2 Génération des échantillons

Dans les tâches de détection de changements SAR, il y a un grand écart entre le nombre de pixels dans les classes modifiées et inchangées, et cela a un grand impact sur la formation DBN. L'entraînement de DBN avec un trop grand nombre d'échantillons sélectionnés de la classe inchangée conduit à une augmentation du temps et provoque le surajustement.

Un ensemble de formation de haute qualité avec un nombre équilibré d'échantillons de chaque classe est demandé. Pour éviter cela, nous générons des échantillons virtuels par la méthode mentionnée ci-dessus dans le but d'enrichir les échantillons d'apprentissage dans la classe changée.

3.3.3 Classification à l'aide d'un réseau de croyances profondes

Le processus de classification des pixels modifiés et inchangés commence par l'extraction des patches d'image centrés sur les pixels sélectionnés (appartenant à Ω_u, Ω_c), à partir des images SAR originales. Les échantillons réels et les échantillons virtuels sont utilisés ensemble comme échantillons d'apprentissage. Les caractéristiques de voisinage de chaque pixel dans l'image 1 et

son correspondant dans l'image 2 sont converties en vecteurs. Les deux vecteurs sont concaténés pour former un vecteur qui sera livré au DBN en entrée. (Figure 3.6).




Figure 3. 6: Processus de génération de caractéristiques de voisinage

3.3.4 Classification finale

Après avoir entraîné le DBN sur la base d'échantillons fiables, les pixels appartenant à Ω_i sont ensuite classés en classes modifiées et inchangées. Nous obtenons la carte de changements finale en combinant le résultat de la classification et le résultat de la pré-classification.

3.4 Résultats expérimentaux et analyse

3.4.1 Configuration expérimentale

Dans cette section, trois ensembles de données d'images SAR réelles ont été utilisés pour évaluer les performances et l'efficacité de notre algorithme. Le Tableau 3.1 présente les détails de chaque ensemble de données utilisé, notamment la taille spatiale, l'emplacement d'imagerie, le temps d'acquisition, et la principale raison du changement.

L'ensemble de données du fleuve Jaune est une section de deux images SAR prises par le Radarsat-2 recueillies dans le fleuve Jaune Zone estuarienne de la Chine en juin 2008 et juin 2009, comme illustré à la Figure 3.7. La taille d'origine du jeu de données est de 7666×7692 pixels. La taille est trop grande pour décrire les détails, par conséquent, les deux régions typiques

(291 x 306 pixels et 444 x 291 pixels) étaient sélectionnées, où différents types de changements se sont produits.

La zone C, correspond au premier jeu de données, les régions modifiées montraient des terres agricoles nouvellement cultivées. La carte de changements de vérité terrain est illustrée à la Figure 3. 8, et elle a été générée par une enquête sur place et des connaissances d'experts.

La zone A, correspond au deuxième jeu de données, elle représente une zone des eaux intérieures, les zones modifiées sont concentrées à la frontière de la rivière Jaune, comme le montre la Figure 3 .9.

Le troisième jeu de données utilisé dans l'expérience est le jeu de données de Berne, capitale de la Suisse. Il se compose de deux images SAR acquises par le satellite ERS-2. Les images ont été capturées en avril et mai 1999, respectivement. Entre les deux dates, la rivière Aare a inondé entièrement des parties de Berne. La taille de cet ensemble de données est de 301×301 . La vérité-terrain disponible illustrée à la Figure 3.10 a été créée en intégrant les informations préalables à la photo-interprétation.




Figure 3. 7: Images multitemporelles relatives à l'estuaire du fleuve Jaune.
(a) Image acquise en juin 2008. (b) Image acquise en juin 2009.

Tableau 3. 1: Détails des ensembles de données.

Nom	Taille	Acquisition t_1	Acquisition t_2	Lieu	Raison du changement
Les terres agricoles de l'estuaire du Fleuve Jaune	291 x 306	June 2008	June 2009	Chine	Agriculture
Fleuve Jaune	444 x 291	June 2008	June 2009	Chine	Inondation
Bern	301 x 301	April 1999	May 1999	Suisse	Inondation




Figure 3. 8: Les terres agricoles de l'estuaire du fleuve Jaune
(a1) image acquise à t_1 , (b1) image acquise à t_2 , (c1) Vérité au sol




Figure 3. 9: Le jeu de données du Fleuve Jaune
(a2) image acquise à t_1 , (b2) image acquise à t_2 , (c2) Vérité au sol




Figure 3. 10: Ensemble de données de Berne
(a3) image acquise à t_1 , (b3) image acquise à t_2 , (c3) Vérité au sol

L'évaluation des performances des méthodes de détection de changements est cruciale. Nous avons utilisé les indicateurs suivants comme critères d'évaluation : Erreurs globales (OE) Eq. (20), classification correcte en pourcentage (PCC) Eq. (21) et le coefficient Kappa (Kappa). Eq. (22).

$$OE = FP + FN. \quad (3.20)$$

$$PCC = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.21)$$

$$Kappa = \frac{PCC - PRE}{1 - PRE} \quad (3.22)$$

Où,

$$PRE = \frac{(TP + FP) \times N_c + (FN + TN) \times N_u}{(TP + TN + FP + FN)^2} \quad (3.23)$$

FP désigne le nombre de pixels appartenant à la classe inchangée qui sont classés incorrectement. FN indique le nombre de pixels appartenant à la classe modifiée qui sont incorrectement classés dans la classe inchangée. N_c et N_u sont les nombres de pixels appartenant respectivement à la classe modifiée et inchangée. Deux méthodes valides ont été implémentées à des fins de comparaison : DeepJFCM [112], NBRELM [130]. Il est à noter que l'indice Kappa est le coefficient le plus convaincant en détection de changement, il mesure les différences entre le résultat de la détection et l'image de référence. Il convient de noter que la simulation est développée en utilisant MATLAB R2016a avec des spécifications matérielles de 12 Go de RAM et de processeur Intel core I5 2,50 GHz.

3.4.2 Résultats expérimentaux

Comme mentionné précédemment, la première étape de notre exécution est une pré-classification effectuée par le JFRFCM qui nécessite une reconstruction de fermeture morphologique, un élément structuel du disque de rayon 3 est utilisé dans tous les jeux de données. Après cela, les échantillons réels et virtuels sont combinés ensemble en tant qu'échantillons d'apprentissage qui sont choisis au hasard parmi Ω_c et Ω_u .

La taille du voisinage « r » dans l'extraction des caractéristiques à partir des images SAR d'entrée est un paramètre important, qui peut également affecter les résultats finaux de la détection de changements. Comme le montre la Figure 3.11, si la taille du voisinage augmente, la détection de

changements à tendance à s'aggraver. Par conséquent, nous définissons $r = 5$ dans nos implémentations. Ensuite, les données sélectionnées doivent être entrées dans le réseau neuronal profond, nous avons utilisé un réseau à 5 couches avec 50, 250, 200, 100 et 1 nœuds pour chaque couche. La taille de lot du réseau égale à 100 et les itérations d'entraînement ont été spécifiées comme 50. Après l'apprentissage, les caractéristiques de voisinage des pixels appartenant à Ω_i sont ensuite classées en classes modifiées et inchangées. Enfin, nous combinons le résultat de la classification DBN et le résultat de la pré-classification pour former la carte de changement finale.




Figure 3. 11: Influence de la taille du quartier dans l'extraction des caractéristiques

3.4.3 Analyse des résultats

3.4.3.1 Effet des échantillons virtuels

Nous testons d'abord l'effet des échantillons virtuels sur la détection de changements final. Comme l'illustre le Tableau 3.2, les valeurs Kappa sont améliorées de 0,60%, de 0,09% et 0,38% sur les trois ensembles de données respectivement. Le réseau neuronal profond avec des échantillons virtuels s'avère être un outil efficace pour les tâches de détection de changements.

Tableau 3. 2: Effet des échantillons virtuels sur les résultats de la détection de changements

Méthodes	Les terres agricoles de l'estuaire du Fleuve Jaune		Bern		Fleuve Jaune	
	PCC (%)	Kappa (%)	PCC (%)	Kappa (%)	PCC (%)	Kappa (%)
Sans échantillons virtuels	98.51	97.14	99.66	99.27	98.53	97.02

Méthode proposée	98.87	97.74	99.69	99.36	98.73	97.40
-------------------------	--------------	--------------	--------------	--------------	--------------	--------------

3.4.3.2 Comparaison de l'algorithme proposé avec d'autres méthodes

➤ La Figure 3.12 montre les résultats de la détection de changements de l'ensemble des terres agricoles de l'estuaire du Fleuve Jaune obtenus par différentes méthodes, à partir desquelles nous pouvons conclure que la méthode proposée a une bonne caractéristique pour résister au bruit de speckle, cela est cohérent avec le tableau 3.3, où PCC et Kappa sont élevés. La valeur Kappa de la méthode proposée est améliorée de 9,47%, 4,54%, par rapport à NBRELM, DeepJFCM, respectivement.

Par ailleurs, la Figure 3.12 (a) montre que certains détails concernant les régions détectées sont manquants, qui sont indiqués par le rectangle rouge. La carte finale de détection de changements obtenue par notre méthode proposée est beaucoup plus proche de l'image de la vérité -terrain.

Tableau 3. 3: Résultats de la détection de changements sur l'ensemble de données des terres agricoles de l'estuaire du Fleuve Jaune

Method	FN	FP	OE	PCC	Kappa (%)
NBRELM	1170	746	1916	97.85	88.27
DeepJFCM	647	1048	1695	98.03	93.20
Méthode proposée	171	834	1005	98.87	97.74




Figure 3. 12: Résultats de la détection de changements obtenus par différentes méthodes sur l'ensemble de données des terres agricoles de l'estuaire du Fleuve Jaune
 (a) Résultats par NBRELM
 (b) Résultats par DeepJFCM
 (c) Résultats par la méthode proposée
 (d) Vérité au sol

➤ Selon l'analyse visuelle de la carte de détection de changements finale générée par différentes méthodes dans l'ensemble de données du Fleuve Jaune illustré à la Figure 3.13. Nous pouvons conclure que par rapport aux autres méthodes, la méthode proposée est moins sensible au bruit, ce qui se traduit par une réduction de l'erreur totale moyenne, et une amélioration des valeurs des coefficients PCC et kappa, le Tableau 3.4 l'indique.

➤ En ce qui concerne le jeu de données de Berne, comme le montre la Figure 3.14, on peut voir la présence de tâches de bruit dans les images de détection de changements finales produites par DeepJFCM tandis que NBRELM est moins sensible au bruit, il est à noter que certains détails des régions modifiées ont disparu. D'après les résultats du Tableau 3.5, la méthode proposée est la meilleure de toutes, elle a permis d'obtenir les meilleurs résultats de PCC et Kappa (PCC = 99,69, Kappa = 99,36).




Figure 3. 13: Résultats de la détection de changement obtenus par différentes méthodes sur l'ensemble du Fleuve Jaune

(a) Résultats par NBRELM

(b) Résultats par DeepJFCM

(c) Résultats par la méthode proposée

(d) Vérité au sol




Figure 3. 14: Résultats de la détection de changement obtenus par différentes méthodes sur l'ensemble de données de Berne

(a) Résultats par NBRELM

(b) Résultats par DeepJFCM

(c) Résultats par la méthode proposée

(d) Vérité au sol

Tableau 3. 4: Résultats de la détection de changements sur l'ensemble de données du fleuve Jaune

Method	FN	FP	OE	PCC	Kappa (%)
NBRELM	792	1165	1957	98.49	82.70
DeepJFCM	1120	746	1866	98.55	96.99
Méthode proposée	869	772	1641	98.73	97.40

Tableau 3. 5: Résultats de la détection de changements sur l'ensemble de données Bern Data

Method	FN	FP	OE	PCC	Kappa (%)
NBRELM	121	190	311	99.66	91.81
DeepJFCM	132	356	488	99.44	96.71
Méthode proposée	132	140	272	99.69	99.36

3.4.4 Comparaison du temps de fonctionnement en ms.

Comme mentionné ci-dessus, nous avons utilisé une pré-classification fondée sur une reconstruction morphologique et un filtrage des membres locaux pour accélérer le processus de sélection d'un ensemble de formation de haute qualité. Une méthode d'échantillonnage virtuel a également été utilisée pour réduire la surapprentissage et accélérer l'optimisation du réseau. Le Tableau 3.6 indique que la mise en œuvre de la méthode proposée prend moins de temps.

Tableau 3. 6: Comparaison du temps de fonctionnement

	NBRELM	DeepJFCM	Méthode proposée
Rivière Jaune	120.15	86.56	15.42
Berne	320.58	280.84	60.54
Terres agricoles de l'estuaire du Fleuve Jaune	260.20	180.94	55.21

3.5 Conclusions

L'étude actuelle présente une méthode de détection de changements d'image directement à partir des images SAR originales, il s'agit d'une méthode non supervisée basée sur un réseau

neuronal profond et ne nécessite aucune connaissance préalable, différente des méthodes existantes qui génèrent une DI. En la comparant avec d'autres méthodes apparentées, il est conclu que la méthode proposée est la plus efficace. Nos deux objectifs principaux étaient de réduire l'impact de la présence de bruit de speckle et aussi le temps de traitement. D'une part, un package de formation de haute qualité a été sélectionné en introduisant une pré-classification rapide et robuste basée sur une reconstruction morphologique et un filtrage des membres locaux, évitant ainsi au réseau de produire beaucoup de fonctionnalités redondantes, et d'autre part, une méthode de génération d'échantillons virtuels a été utilisée qui tente d'enrichir les échantillons d'apprentissage, ce qui se traduit par une réduction du surajustement et une optimisation plus rapide du réseau.

Chapitre 4

Méthode de détection de changements basée sur un réseau neuronal à capsules

Le présent chapitre s'inspire de l'article intitulé :

Attioui, S., Najah, S. Multidimensional parallel capsule network for SAR image change detection. *Multimedia Tools and Applications* (2022).

Il instaure un nouveau cadre dans lequel le problème de détection de changements est réglé en mettant à profit le réseau de capsules.

Depuis leur avènement, les techniques d'apprentissage profond (DL) ont fait de grandes percées dans le problème de détection de changements en imagerie radar à synthèse d'ouverture (SAR). Pourtant, leur efficacité et leur précision avec une présence de bruit de speckle et de données d'entraînement étiquetées limitées sont toujours pleines de défis. Pour surmonter ces problèmes, ce chapitre préconise une approche innovante en exploitant l'avantage du réseau de capsules qui peut atteindre une performance similaire avec moins d'échantillons d'entraînement grâce à sa capacité à tirer pleinement parti des relations spatiales relatives entre les entités.

Le réseau de capsules parallèles multidimensionnelles proposé (Mdp-CapsNet) comprend un module d'attention pour atténuer les interférences du bruit de speckle. En se concentrant davantage sur les parties importantes des cartes d'entités, le module d'attention guide le réseau pour améliorer l'extraction des entités. De plus, une fonction de perte focale de marge est suggérée pour surmonter l'influence d'échantillons déséquilibrés lors de l'optimisation du réseau. L'efficacité et la fiabilité de la méthode proposée sont démontrées en comparant ses résultats avec d'autres méthodes de pointe.

4.1 Introduction

Au cours des dernières années, l'étalement urbain et les dommages accrus causés par les catastrophes naturelles (tremblements de terre, inondations, incendies de forêt, etc.) ont contribué à l'importance croissante de la technologie de détection de changements à l'aide des

images de télédétection, car elle a fait l'objet d'une attention considérable de la part d'innombrables chercheurs dont le but a été d'identifier, de mettre en évidence et de comprendre l'évolution temporelle du changement à partir d'une série d'observations acquises sur les mêmes zones cibles à différents moments.

Le radar à synthèse d'ouverture (SAR) est un radar d'imagerie cohérent et micro-ondes, avec ses capacités tout temps et à tout moment pour fournir une résolution d'image spatiale élevée, il est devenu un outil d'investigation exceptionnel pour de nombreuses missions où les capteurs visibles sont mal adaptés.

En tant que l'une des applications importantes, la détection de changements, qui vise à identifier la présence des changements d'origine humaine ou naturelle à la surface, est d'une grande valeur pratique dans de nombreux domaines, tels que l'urbanisme [132] et la gestion des catastrophes [4] .

Bien que la détection de changements à l'aide d'images SAR devienne intéressante et efficace, il s'agit toujours d'un sujet brûlant. En général, les images SAR sont beaucoup plus difficiles à interpréter par les opérateurs humains que les images optiques, et la capacité d'interpréter leurs détails est limitée. Par conséquent, leurs interprétations s'avèrent chronophages et plutôt coûteuses. De plus, l'imagerie SAR comprend intrinsèquement des distorsions géométriques et l'apparence des cibles dépend grandement de l'orientation relative entre le capteur et la cible. Enfin, la présence de bruit de speckle perturbe son traitement et entrave sérieusement l'interprétation de ses résultats.

À cette fin, des efforts sont toujours en cours pour la reconnaissance automatique des images SAR pour sa capacité à extraire toutes les informations disponibles, surmontant ainsi les limites des opérateurs humains, tout en cherchant à trouver des procédures de détection de changements robustes et fiables contre le bruit de speckle.

Pour résoudre ces problèmes, plusieurs méthodes ont été mises en œuvre qui peuvent être classées comme des approches d'apprentissage supervisées [133] [134], non supervisées [135] [70]. Les méthodes d'apprentissage supervisé nécessitent à l'avance des informations appropriées sur la vérité de terrain pour générer un ensemble de formation afin d'acquérir une classification robuste. Cependant, en raison de l'effet des interférences atmosphériques, de la différence d'angle de vision du capteur et des résolutions, il est difficile d'obtenir suffisamment de données étiquetées fiables.

Les approches d'apprentissage non supervisé ont fait l'objet d'une grande attention, car elles ne requièrent pas de connaissances préalables et sont donc devenues le courant dominant dans les tâches de détection de changements.

Ce chapitre se concentre donc sur le développement d'une méthode de détection de changements de manière non supervisée.

La détection de changements non supervisée est généralement composée de trois étapes principales suivantes : (1) traitement d'image, (2) génération d'image de différence (DI) et (3) analyse DI.

La première étape est conçue pour aligner les deux images SAR dans les mêmes niveaux de gris et coordonnées spatiales, ce qui permet de les comparer. Cette étape comprend principalement le co-enregistrement de l'image, la correction géométrique, ainsi que la correction radiométrique et le débruitage.

La deuxième étape consiste à générer une image de différence (DI). Diverses méthodes ont été proposées avec succès basée sur l'opérateur de soustraction ou l'opérateur de rapport (R). La racine de l'erreur quadratique moyenne (RMSE), qui mesure la différence moyenne pixel par pixel entre les deux images, est également utilisée pour la génération de DI.

Bien que l'opérateur de soustraction puisse découvrir les changements dans une faible mesure, des recherches antérieures ont prouvé que l'opérateur de rapport (R) est plus approprié que l'opérateur de soustraction qui est facilement influencé par le bruit. Des efforts ont été entrepris pour améliorer l'opérateur de rapport R afin de générer une meilleure image de différence. Les méthodes les plus utilisées sont l'opérateur rapport logarithmique [136], l'opérateur du rapport logarithmique de Gauss [1], les opérateurs de rapport basé sur le voisinage [61].

La similitude structurelle (SSM), conçue pour mesurer la similitude de deux images en termes d'intensité, de luminosité et de contraste, a également été proposée dans la détection de changements d'images radar à synthèse d'ouverture (SAR). Comme la SSM est utilisée pour estimer la similitude globale d'une image, il y a une grande erreur lorsque l'on compare la similitude locale, ce qui affecte considérablement ses performances. Les expériences ont montré que le SSIM n'est pas adapté à la détection de changement dans les images SAR.

Bien que ces méthodes soient fréquemment utilisées en raison de leur rapidité et de leur simplicité, elles sont néanmoins sujettes à plusieurs lacunes, telles que les effets du bruit de speckle et les erreurs d'enregistrement inévitables, qui affectent toutes deux la précision de la carte finale de détection de changements.

La dernière étape de la détection de changements non supervisée est essentielle car elle vise à générer la carte des changements finaux, où les différences entre les deux images sont soulignées. Il s'ensuit que la tâche de détection de changements peut être considérée comme un problème de classification binaire. Les méthodes de seuillage [70] [137] et de clustering [121] [71] sont les deux méthodes les plus couramment utilisées en l'occurrence.

Dans les méthodes de seuillage, plusieurs approches ont été proposées pour sélectionner automatiquement un seuil optimal basé sur la construction d'un modèle statistique, tels que l'algorithme espérance-maximisation (en anglais Expectation-Maximization (EM)) [138], et l'algorithme du seuil minimum de Kittler-Illingworth (KI) [59]. Bien que ces méthodes de seuillage soient simples, elles rencontrent souvent des difficultés lorsque leur distribution statistique ne peut pas être modélisée avec précision et finissent par donner des résultats instables.

Pour éviter les inconvénients des approches de seuillage, des techniques de regroupement (Clustering) ont été proposées. La plupart d'entre elles ont été massivement utilisées et couronnées de succès, telles que : Fuzzy c-means, k-means, normalized cut, etc.

L'algorithme de clustering Fuzzy C-Means (FCM) est l'un des plus célèbres algorithmes de clustering qui a été appliqué avec succès à la classification d'images. Le FCM est un algorithme de clustering souple, qui permet à chaque point de données d'appartenir à deux ou plusieurs centres de clustering avec différents degrés d'appartenance. Bien que l'algorithme FCM standard fonctionne bien sur les images sans bruit, il ne prend en compte aucune information sur le contexte spatial, ce qui le rend sensible au bruit et à d'autres reliques d'imagerie.

Pour améliorer la déficience de FCM traditionnel, plusieurs variantes de FCM basées sur l'information spatiale ont été suggérées, telles que FCM_S [117], FCM_S1 [118], FCM_S2 [118], EnFCM [119] et FGFCM [120]. Pour améliorer encore la robustesse de l'algorithme, Krinidis et al. [121] ont proposé l'algorithme FLICM (Fuzzy Local Information C-Means), qui incorpore l'information spatiale locale en tant que facteur flou dans sa fonction objective visant à améliorer les performances du clustering tout en assurant l'immunité au bruit et la préservation des détails. Dans [139], un clustering k-means à noyaux multiples avec une méthode d'information de voisinage local est suggéré pour améliorer les performances de détection de changements. La méthode de regroupement flou multi-objectifs (MOFCM) a été abordée par Li et al. [140] qui ont proposé une méthode qui obtient un ensemble de solutions représentant diverses relations de compromis entre la restriction du bruit et la protection des détails.

L'algorithme de clustering K-Means, une technique de partitionnement basée sur les centroïdes, qui vise à répartir les échantillons de données en k groupes, a également été appliqué avec succès au problème de la classification des images. Bien que son efficacité et son efficacité aient été prouvées, il dépend généralement du nombre de clusters fournis a priori, ce qui est difficile à réaliser dans un ensemble de données à haute dimension contenant un grand nombre de caractéristiques non pertinentes ou de bruit, ce qui peut avoir un impact sur l'exécution du clustering. Une variété d'améliorations et d'algorithmes d'extensions ont été proposés pour surmonter ce problème en combinant le clustering K-Means avec l'apprentissage du sous-espace. Xiao-Dong Wang et al. [90] ont développé un clustering de sous-espace K-means auto-adjacent (AKSC) pour les données d'image à haute dimension qui peut apprendre automatiquement la matrice d'adjacence selon la connectivité locale et les informations de cluster, en diminuant l'effet du bruit et des caractéristiques non pertinentes. En concevant une fonction de perte adaptative pour fournir un mécanisme de calcul d'indicateur de cluster flexible. Wang et al. [141] ont proposé un modèle de clustering de sous-espace de type k -moyennes adaptatif rapide (nommé FAKM) qui convient aux données à haute dimension, en combinant K-means et la sélection des caractéristiques dans un cadre cohérent sans la décomposition des valeurs propres.

Même si les algorithmes de classification améliorés ci-dessus aient atteint des performances prometteuses, de nombreux obstacles entravent leurs performances, tels que le bruit de speckle, le temps de traitement et les coûts de calcul élevés. De ce fait, la détection de changements reste un sujet pressant et persistant, et la conception d'un classificateur puissant est devenue nécessaire.

Les énormes progrès récemment réalisés dans la vision par ordinateur et le développement rapide d'algorithmes sophistiqués d'analyse d'images et d'apprentissage automatique ont généré un grand nombre de percées en termes d'efficacité et de précision dans un certain nombre de tâches visuelles où une variété d'œuvres très complexes a été étudiée. Ainsi, la conception d'outils automatiques capables d'extraire et d'analyser toutes les informations disponibles dans les images SAR est devenue possible. Gao et al. [90] ont proposé d'utiliser un cadre de regroupement hiérarchique FCM pour la sélection des échantillons avec l'adoption de la machine d'apprentissage extrême (ELM) comme classificateur. Gong et al. [112], ont proposé d'utiliser une méthode basée sur des machines Boltzmann restreintes empilées (RBM) pour la détection de changements d'image SAR. Malgré les bons résultats

obtenus par les méthodes ci-dessus, les capacités de représentation des fonctionnalités restent encore limitées.

Au cours des dernières années, les réseaux de neurones convolutifs (CNN) ont apporté des améliorations spectaculaires à de nombreuses tâches visuelles, telles que la classification des images [142]. Ils ont montré une robustesse surclassant les autres modèles neuronaux, ainsi que les performances humaines. Derrière ce grand succès se cache leur puissante capacité à extraire automatiquement des fonctionnalités d'image multi-niveaux. Motivées par ces applications réussies, des tentatives significatives ont été mises en œuvre avec succès dans la détection de changements à l'aide d'image de télédétection basées sur les réseaux de neurones convolutifs (CNN). Qing et al. [143] ont suggéré l'application du réseau neuronal convolutif basé sur une région plus rapide (Faster R-CNN) à la détection de changements SAR, réduisant considérablement les faux positifs et les faux négatifs des résultats de la détection. Li et al. [75] ont proposé une méthode de détection de changement d'image SAR basée sur un réseau neuronal convolutif, Wang et al. [114] ont conçu un cadre nommé GETNET (General End-to-end Two-dimensional CNN), visant à en apprendre davantage sur les caractéristiques discriminantes des matrices d'affinité mixte 2D pour la détection de changements. Liu et al. [144] ont proposé un CNN local restreint (LRCNN) pour détecter les zones modifiées dans la détection polarimétrique des changements SAR. Dong et al. [145] ont conçu un réseau neuronal convolutif "échantillons siamois" pour en apprendre davantage sur la différence sémantique correcte entre les pixels modifiés et inchangés.

Dans l'ensemble, bien que les méthodes basées sur CNN aient connu un succès significatif dans le domaine de la détection de changements, il existe encore des lacunes et des limitations qui limitent leurs applications. Les insuffisances suivantes sont à noter :

- ✓ CNN est incapable d'apprendre les hiérarchies spatiales entre les caractéristiques. Il en résulte que CNN nécessite une énorme quantité de données d'apprentissage pour couvrir des variantes dissemblables, provoquant ainsi la disparition du gradient et la saturation de la précision.

- ✓ Le déséquilibre de l'échantillon peut également entraîner un sous-ajustement ou un surajustement de la formation du modèle CNN, ce qui entraîne une détérioration de la précision.

- ✓ La couche de mise en commun dans CNN est adoptée pour réduire la dimensionnalité de la représentation, ce qui pourrait entraîner une perte de certaines

informations spatiales (par exemple, l'emplacement) dans la progression vers l'avant, empêchant ainsi le réseau d'apprendre des objets très précieux à des fins de localisation et de classification.

Dans une tentative de surmonter ces insuffisances, le groupe Hinton [146] [147] a proposé un nouveau concept dans un système d'apprentissage automatique connu sous le nom de réseaux de capsules (CapsNets), l'idée clé innovante étant la réalisation d'une équivariance de traduction en codant les relations hiérarchiques existant entre diverses entités.

Le module capsule est un nouveau réseau neuronal, robuste aux transformations affines, construit avec plusieurs couches de capsules, où chaque capsule est constituée d'un petit groupe de neurones comprenant des paramètres d'instanciation tels que la position, la taille, l'orientation, la texture et la déformation, brisant ainsi la limitation des CNN classiques qui sont construits sur la base de représentations de neurones scalaires. Plus précisément, la longueur des paramètres d'instanciation code la probabilité qu'une entité particulière existe.

Bien que CapsNet n'en soit qu'à ses débuts, il a reçu une considération substantielle au sein de la communauté des chercheurs en raison de ses propriétés supérieures de codage des caractéristiques. Il a été exploité pour de nombreuses tâches, notamment pour la reconnaissance d'actions faciales [148] et la classification d'images hyperspectrales [149] [150] .

Son application aux études liées à la détection de changements dans les images SAR reste cependant assez rare. Gao et coll. [151] ont proposé un réseau de capsules multi-échelles pour la détection de changements d'image SAR. Plus précisément, un module de capsule multi-échelle a été appliqué pour obtenir des caractéristiques robustes à partir des images originales.

En améliorant la caractéristique de robustesse, un module de convolution de fusion adaptative a été conçu pour limiter les interférences sonores. Même si cela a raisonnablement amélioré la précision de la détection des changements dans une certaine mesure, dans sa première étape, l'extraction des caractéristiques n'est obtenue que par une seule couche de convolution scalaire, ce qui diminue en temps voulu les performances du réseau dans la classification complexe en l'absence d'informations sémantiques de haut niveau.

Le module de capsule parallèle multidimensionnelle proposé dans notre étude est précisément destiné à résoudre ce problème. Inspirés par la structure de [152], nous proposons dans cette étude d'appliquer un réseau de capsules parallèles multidimensionnelles pour le problème de détection de changements d'image SAR.

L'architecture proposée est mise en place afin d'améliorer la capacité du réseau à extraire des fonctionnalités plus riches et robustes. Encouragée par les progrès récents, l'architecture adopte un module simple pour résoudre le problème du bruit de speckle.

Les principales contributions du travail peuvent donc être résumées comme suit :

1. Nous suggérons d'utiliser un réseau de capsules parallèles multidimensionnelles qui vise non seulement à extraire des fonctionnalités robustes, mais aussi à modéliser leurs relations hiérarchiques, et par là, nous obtenons des résultats optimaux avec moins d'échantillons d'entraînement.
2. Afin de réduire l'influence des échantillons déséquilibrés lors de l'optimisation du réseau, une fonction de perte marginale-focale est utilisée pour augmenter l'attention portée aux échantillons mal classés.
3. Cette architecture comprend un module d'attention visant à atténuer l'interférence du bruit de speckle. Son rôle consiste à convertir les intensités de pixels en activités de caractéristiques locales. Ces sorties sont ensuite introduites comme entrées à la couche de la capsule primaire. En accordant une meilleure attention aux pixels, le module extrait les caractéristiques les plus relatives avec des informations sémantiques de haut niveau et élimine les informations bruyantes et distrayantes.

4.2 Préliminaires et méthode de détection de changements proposée

4.2.1 FLICM pour la détection de changements

Parmi les méthodes de détection de changements basées sur le clustering, l'algorithme Fuzzy C-means (FCM) a reçu une grande attention. Cependant, il est toujours sensible au bruit car il ignore les relations spatiales entre les pixels. Krinidis et al. [121] ont proposé un algorithme robuste de clustering Fuzzy C-means à information locale (FLICM), qui prend en compte les informations de contexte spatial pour assurer l'insensibilité au bruit et la préservation des détails de l'image.

La fonction objective peut être calculée selon (1) et (2) :

$$J_m = \sum_{i=1}^N \sum_{k=1}^c [\mu_{ik}^m \|x_i - v_k\|^2 + G_{ik}] \quad (4.1)$$

$$G_{ik} = \sum_{j \in N_i, i \neq j} \frac{1}{d_{ij} + 1} (1 - \mu_{ik})^m + \|x_j - v_k\|^2 \quad (4.2)$$

Où G_{ik} est le nouveau facteur flou qui contient les informations spatiales locales et les informations de niveau de gris. N_i représente l'ensemble des pixels adjacents entourant le $i^{\text{ème}}$ pixel avec une taille (par exemple, 3×3). d_{ij} est la distance euclidienne spatiale entre les pixels i et j . μ_{kj} désigne le degré d'appartenance du $j^{\text{ème}}$ pixel dans le $k^{\text{ème}}$ cluster.

En minimisant la fonction objective, la matrice de partition d'appartenance et les centres de cluster peuvent être obtenus comme suit :

$$\mu_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{\|x_i - v_j\|^2 + G_{ij}}{\|x_i - v_k\|^2 + G_{ik}} \right)^{\frac{1}{m-1}}} \quad (4.3)$$

$$v_j = \frac{\sum_{i=1}^N (\mu_{ij})^m x_i}{\sum_{i=1}^N (\mu_{ij})^m} \quad (4.4)$$

4.2.2 Mécanisme d'attention

Le mécanisme d'attention est une partie importante de la perception humaine. Il vise à mettre en évidence les régions pertinentes des données d'entrée pour résoudre une tâche spécifique au lieu d'ingérer complètement l'entrée. Il a été proposé pour la première fois dans les tâches de traitement du langage naturel (NLP), obtenant ainsi des résultats très prometteurs. Depuis lors, il a suscité un intérêt considérable, et plusieurs travaux se sont concentrés sur l'intégration des mécanismes d'attention dans de nombreux problèmes de vision par ordinateur, qui se sont avérés très réussis, tels que la réponse visuelle aux questions (VQA), la restauration d'images et le sous-titrage ou la classification d'images.

Hu et al. [153] ont proposé les blocs Squeeze-and-Excitation (SE) dans les réseaux SE-Nets, atteignant une performance significative pour la classification d'image en modélisant des relations par canal dans un mécanisme d'attention. Zhang et al. [154] ont construit un réseau d'attention par canal résiduel très profond, qui intègre l'attention par canal aux réseaux

résiduels, montrant la contribution de l'attention par canal à l'amélioration de la précision de la super-résolution d'image.

Un module d'attention comprenant deux sous-modules connectés de manière séquentielle : l'attention par canal (CA) et l'attention spatiale (SA) sont conçues pour le Ms-CapsNet proposé.

L'attention par canal (CA) est adoptée pour mettre l'accent sur les canaux les plus liés à la zone de l'objet, puis pour promouvoir ces canaux informatifs tout en éliminant les moins utiles.

L'attention spatiale (SA), qui peut être considérée comme complémentaire à l'attention par canal, elle est conçue pour assurer un raffinement de la carte des entités à partir du niveau des pixels.




Figure 4. 1: Module d'attention à blocs convolutif

Comme l'illustre la Figure 4.1, étant donné une carte d'entités d'entrée $F \in \mathbb{R}^{H \times W \times C}$, une couche de regroupement moyen global GAP (Global Average Pooling) en tant qu'opération de d'écrasement (Squeeze) est d'abord appliquée pour chaque canal afin d'acquérir la carte d'attention de canal $F_{Avg} \in \mathbb{R}^{1 \times 1 \times C}$.

Les détails de F_{Avg} sont indiqués ci-dessous (5) :

$$f_{AvgC} = GAP(f_C) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W f_C(i, j) \quad (4.5)$$

Où f_C désigne le $C^{ème}$ canal dans la carte de caractéristiques d'entrée $F \in \mathbb{R}^{H \times W \times C}$

f_{AvgC} , représente le $C^{ème}$ nombre réel de la carte d'attention du canal $F_{Avg} \in \mathbb{R}^{1 \times 1 \times C}$

Ensuite, pour explorer davantage la relation de canal de F_{Avg} , nous implémentons une convolution 1D, et ensuite, une fonction sigmoïde est utilisée pour générer le vecteur M_C basé sur la pondération du canal.

En conséquence, la carte de caractéristiques raffinées de canal peut être exprimée sous la forme de l'équation suivante :

$$F' = M_c \otimes F = \sigma(AvgPool(F)) \otimes F = \sigma(F_{Avg}) \otimes F \quad (4.6)$$

Où $\otimes$ désigne la multiplication par élément et σ désigne la fonction sigmoïde.

En complément du module d'attention par canal, nous concevons en outre le mécanisme d'attention spatiale, qui utilise les relations spatiales entre les entités pour produire une carte d'attention spatiale, assurant ainsi un raffinement de la carte d'entités à partir du niveau des pixels. Compte tenu des entités affinées par canal, l'opération de mise en commun moyenne (average pooling) est implémentée sur tous les canaux d'entités le long de l'axe du canal pour acquérir une carte d'entités $F'_{Ap} \in R^{H \times W \times 1}$. Le choix de conception d'une telle méthode de mise en commun est présenté empiriquement dans la section suivante.

$$f'_{Apij} = AP(f'_{ij}) = \frac{1}{C} \sum_{k=1}^C f'_{ij}(k) \quad (4.7)$$

Où f'_{ij} désigne la valeur de pixel du point ij dans la sortie du module d'attention de canal F' .

f'_{Apij} , indique la valeur en pixels du point ij dans la carte des entités $F'_{Ap} \in R^{H \times W \times 1}$.

Ensuite, une opération de convolution avec une taille de filtre 3×3 et une fonction sigmoïde sont implémentées pour générer la carte d'attention spatiale M_s . Enfin, la sortie finale raffinée est acquise par une multiplication par éléments de F' et M_s .

Le processus est le suivant :

$$\begin{aligned} F'' &= M_s \otimes F' = \sigma(Ap(F')) \otimes F' \\ &= \sigma(F'_{Ap}) \otimes F' \end{aligned} \quad (4.8)$$

4.2.3 Méthodologie proposée pour la détection de changements SAR

Soient deux images SAR multi-temporelles co-enregistrées I_1 et I_2 , avec la même taille $M \times N$, acquises à t_1 et t_2 sur la même zone géographique.

$$I_1 = \{I_1(i, j), 1 \leq i \leq M, 1 \leq j \leq N\}$$

$$I_2 = \{I_2(i, j), 1 \leq i \leq M, 1 \leq j \leq N\}$$

L'objectif est de générer une carte de changement binaire qui montre le changement d'information qui s'est produit entre les deux images. L'organigramme de la méthode proposée est illustré à la Figure 4.2.




Figure 4. 2: Organigramme de la méthode de détection de changements proposée

Les principales étapes de la méthode proposée sont détaillées de la manière suivante :

- **Étape 1. Pré-classification** : L'opérateur du rapport logarithmique est adopté pour générer une (DI). Ensuite, l'algorithme FLICM est appliqué pour générer des échantillons appropriés.
- **Étape 2. Entraînement du modèle Mdp-CapsNet** : à partir de deux images SAR d'entrée originales, de nouveaux patches d'image autour de chaque pixel intéressé obtenu à l'étape précédente sont générés. Le modèle Mdp-CapsNet est entraîné à l'aide de ces patches.
- **Étape 3. Classification des pixels modifiés et inchangés** : Après avoir entraîné le Mdp-CapsNet sur la base d'échantillons fiables, les pixels restants de l'étape 1 sont ensuite classés en classes modifiées et inchangées. La carte de changement finale est obtenue en combinant le résultat de la classification et le résultat de la pré-classification.

4.2.4 Pré-classification

Les images SAR étant principalement affectées par un bruit de speckle de nature multiplicative. L'opérateur du rapport logarithmique est l'une des techniques les plus largement utilisées pour obtenir une DI. Avec l'opérateur log-ratio, le bruit de speckle multiplicatif peut être transformé en un bruit additif. Dans une certaine mesure, l'effet négatif du bruit peut être limité. L'opérateur permettant d'obtenir une DI est calculé comme suit :

$$DI = |\log(I_1 + 1) - \log(I_2 + 1)| \quad (4.9)$$

Dans le processus d'utilisation de l'opérateur de rapport logarithmique, nous utilisons $I_i + 1$ ($i = 1, 2$) afin d'éviter le cas où les valeurs de pixels dans I_i ($i = 1, 2$) soient des zéros, ce qui rendrait (9) absurde.

Après avoir obtenu DI, l'algorithme FLICM (Fuzzy Local Information c-Means) a été appliqué pour assigner chaque pixel de la DI dans la classe modifiée Ω_c ou inchangée Ω_u ou intermédiaire Ω_i . Les pixels assignés à Ω_c et Ω_u font référence à des pixels qui ont une forte probabilité d'être modifiés et inchangés, ces deux types de pixels sont pris comme échantillons d'apprentissage. Les autres pixels affectés à la classe intermédiaire qui occupe une grande partie de l'image du rapport logarithmique seront ensuite classés par Mdp-CapsNet. Les patches d'image centrés sur les échantillons fiables (pixels appartenant aux deux classes) sont extraits de l'image originale I_1 et de l'image correspondante I_2 . Les deux patches sont combinés pour former une nouvelle image.

4.2.4.1 Formation du modèle Mdp-CapsNet

Comme mentionné précédemment, le processus de classification des pixels commence par l'extraction des patches d'image centrés sur des pixels fiables (appartenant à Ω_c, Ω_u) à partir des deux images SAR d'entrée. Les caractéristiques de voisinage de chaque pixel de l'image 1 et de son correspondant dans l'image 2 sont concaténées pour former un nouveau patch d'image qui sera livré au modèle Mdp-CapsNet en tant qu'entrée.

Nous avons conçu un Mdp-CapsNet qui est illustré à la Figure 4.3. Les processus adoptés sont les suivants :

➤ **Couche de convolution** : La couche de convolution est utilisée pour convertir les intensités de pixels en activités des caractéristiques locales à utiliser comme entrée dans les capsules primaires. Contrairement au réseau de capsules d'origine, qui utilise une seule couche de convolution scalaire, cela rend le réseau peu performant dans une classification complexe. Nous avons proposé d'utiliser trois couches de convolutions de différents niveaux nommées Conv1, Conv2 et Conv3, qui fournissent des cartes caractéristiques et des relations spatiales plus efficaces à partir des images originales.

La première couche contient 8 noyaux avec un stride de 2. Les noyaux des deuxième et troisième couches sont respectivement 16 et 32, avec un stride de 2 et ReLU comme fonction d'activation.




Figure 4. 3: Organigramme illustrant la méthode de détection de changements proposée basée sur Mdp-CapsNet

L'introduction d'un mécanisme d'attention aux trois sorties finales des trois couches de convolution a permis de mettre en évidence les caractéristiques significatives le long des deux dimensions principales : le canal et les axes spatiaux.

Le module d'attention met en évidence les objets ou les régions les plus saillants de l'image d'entrée, ce qui a permis à la capsule de se concentrer sur une plus grande zone de l'image, obtenant ainsi plus d'informations et d'améliorer la précision de la classification.

➤ **Couche de capsule primaire** : La couche se compose de trois processus distincts : convolution, la fonction de remodelage (Reshape function) la fonction d'écrasement (Squash function). Le module parallèle multidimensionnelle de la capsule reçoit les cartes de caractéristiques de différentes tailles obtenues par les trois couches de convolution standard (Conv1, Conv2, Conv3) basées sur le module d'attention.

Ensuite, trois opérations de type convolutionnels avec une taille de noyau $k = 3$ et des pas de 1, 2 et 3, respectivement, et la fonction d'activation d'écrasement non linéaire mentionnée ci-

dessous, sont appliquées à la matrice F_j'' pour générer trois vecteurs de caractéristiques notés, $v_p^k \in R^d$, $k=1,2,3$ et $d=8$.

La fonction d'activité d'écrasement est la suivante :

$$v_j = \frac{\|S_j\|^2}{1 + \|S_j\|^2} \frac{S_j}{\|S_j\|} \quad (4.10)$$

Où v_j se réfère à la sortie vectorielle de la $j^{\text{ème}}$ capsule et S_j est son vecteur d'entrée total, la fonction d'écrasement est utilisée pour réduire la longueur du vecteur de sortie d'une capsule à $[0,1]$ afin qu'elle se présente comme une probabilité réelle sans changer sa direction.

➤ **Couche Conv-Capsule :** La fonction principale de cette couche est de réduire le nombre de paramètres en utilisant des connexions locales et la matrice de pondération partagée. Dans nos implémentations, les cartes de caractéristiques connectées sont utilisées comme entrée de la couche Conv-Capsule. Chaque capsule de la couche précédente tente de prédire la sortie de la couche conv-capsule à l'aide d'une matrice de poids entraînable W_{ij} , qui modélise une relation « partie-tout » entre les entités représentées par les deux capsules, comme suit :

$$\hat{u}_{j/i} = W_{ij} v_{pi} \quad (4.11)$$

Où $\hat{u}_{j/i}$ désigne la prédiction faite par la capsule de caractéristique de bas niveau i pour la capsule de caractéristique de haut niveau j , et v_{pi} est la sortie de la capsule de caractéristique de bas niveau i .

Ensuite, tous les vecteurs de prédiction sont ensuite regroupés pour générer le vecteur d'entrée S_j de la capsule de caractéristique de haut niveau j , comme suit :

$$S_j = \sum_i c_{ij} \hat{u}_{j/i} \quad (4.12)$$

Où le scalaire c_{ij} fait référence aux coefficients de couplage, déterminés par le degré de similitude entre le vote généré par la capsule i et la capsule j .

Les coefficients sont calculés à l'aide du processus de routage dynamique itératif, comme suit :

$$c_{ij} = \frac{\exp(b_{ij})}{\sum_k \exp(b_{ik})} \quad (4.13)$$

Où b_{ij} se réfère au coefficient de couplage avant normalisation, il est d'abord défini sur 0.

La sortie v_{Ci} de la couche conv-capsule est obtenue par activation de la fonction squash, comme suit :

$$v_{Cj} = \text{squashing}(S_j) \quad (4.14)$$

La dernière étape consiste à ajuster les coefficients de routage par la mise à jour de la fonction, qui est donnée par Eq (15)

$$b_{ij} \leftarrow b_{ij} + \hat{u}_{j/i} v_{Cj} \quad (4.15)$$

Après un nombre itératif d'itinéraire présélectionné, la boucle est terminée. Nous acquérons la sortie finale de la capsule de fonctionnalités de haut niveau.

Le processus de routage dynamique par accord est illustré dans l'Algorithme 1.

Algorithme 1 Routage dynamique

```

1: procedure Routing ( $\hat{u}_{j/i}$ , m, l)
2: for every l layer capsule i to (l+1) layer capsule j do
3:    $W_{ij} \leftarrow 0$ ;
4:   for iteration 1 to m do
5:     for all capsule i in layer l do
6:        $c_i \leftarrow \text{softmax}(b_i)$ ;
7:       for all capsule j in layer (l+1) do
8:          $S_j \leftarrow \sum_i C_{ij} * \hat{u}_{j/i}$  ;
9:       for all capsule j in layer (l+1) do
10:         $v_{Cj} \leftarrow \text{squash}(S_j)$ ;
11:       for all capsule i in layer l and capsule j in layer (l + 1) do
12:         $b_{ij} \leftarrow b_{ij} + \hat{u}_{j/i} v_{Cj}$ ;
13: return  $v_{Cj}$ 

```

➤ **Couche de capsule de classe :** La couche finale est une couche de capsule entièrement connectée, avec deux capsules 16D, chacune d'entre elles représentant une classe, et utilise toujours l'algorithme de routage dynamique. L'entrée de toutes les capsules de la couche inférieure est acheminée vers son chemin, en conséquence, une carte de probabilité de changement peut être obtenue en calculant la longueur des vecteurs de capsule de sortie $\mathbf{v}$, ce qui représente la probabilité qu'un pixel appartienne à une classe.

Un problème de déséquilibre des classes s'est alors posé en tant qu'un des défis de la classification.[155]. Compte tenu de l'importance de ce problème, un grand nombre de techniques ont été mises au point pour tenter de résoudre le problème [156].

Lors de l'entraînement du modèle, nous avons identifié un grand écart entre le nombre de pixels dans les classes modifiées et inchangées. L'étape suivante consiste à se concentrer sur la conception d'une excellente fonction de perte destinée à rendre l'algorithme hautement efficace, opérationnel et précis.

Dans [157], une perte focale a été proposée pour surmonter le déséquilibre de classe, ce qui est très approprié pour notre algorithme. En tenant compte de la perte de marge (m^+ et m^-) utilisée dans [147], nous améliorons la perte focale avec une perte de marge qui garantit que le réseau se concentre sur l'optimisation de l'échantillon mal classé, la perte focale de marge est définie pour la classe k comme :

$$\begin{aligned} L_k = & -\alpha y_k (\max\{0, m^+ - \|v\|\})^\gamma \log(\|v\|) \\ & -(1-\alpha)(1-y_k)(\max\{0, \|v\| - m^-\})^\gamma \\ & \times \log(1 - \|v\|) \end{aligned} \quad (4.16)$$

Où y_k représente l'étiquette pendant l'entraînement ($y_k = 0$ signifie que le pixel correspondant appartient à la classe inchangée, $y_k = 1$ signifie la classe modifiée).

Les termes m^+ , m^- , γ , α sont les hyper-paramètres du modèle.

Les bornes supérieure et inférieure m^+ et m^- sont les mêmes que celles du modèle original. γ est un paramètre de focalisation, et $\alpha \in [0,1]$ est utilisé comme facteur de pondération.

4.2.4.2 Classification des pixels modifiés et inchangés

En utilisant le modèle Mdp-CapsNet entraîné, les pixels appartenant à Ω_i sont séparés en deux classes : modifiées et inchangées.

Enfin, nous combinons le résultat de la classification Mdp-CapsNet et le résultat de la pré-classification pour former la carte de changement finale.

4.3 Résultats et discussion

Dans cette section, l'évaluation des performances de la méthode proposée a été effectuée sur quatre ensembles de données SAR réels. Nous commençons par décrire ces ensembles de données ainsi que les critères d'évaluation adoptés. Ensuite, nous menons des expériences pour démontrer pleinement l'efficacité de la contribution de divers paramètres dans la détection de

changements. Enfin, nous comparons l'approche proposée avec certaines techniques classiques et plus récentes de détection de changements.

4.3.1 Description de l'ensemble de données et critères d'évaluation

Dans cette étude, nous avons sélectionné quatre ensembles de données SAR multi-temporelles acquises par différents capteurs afin d'évaluer les performances de Mdp-CapsNet proposé.

Les premiers ensembles de données utilisés dans les expériences, comme indiqué dans les trois premières lignes de la Figure 4.5 (a)-(c), les trois sections représentatives sont sélectionnées à partir de deux images SAR de grande taille 7666×7692 acquises par Radarsat-2 dans la même région de l'estuaire du fleuve Jaune en Chine en juin 2008 et juin 2009.

Les deux premières images appelées Yellow River A et Yellow River B, relatives à des terres agricoles d'une taille de 257×289 et 306×291 pixels, respectivement. Les images de référence disponibles représentent les zones modifiées, sont créées en intégrant des informations préalables avec l'interprétation des photos. L'effet du bruit de chatoiement sur l'ensemble des données est assez important, ce qui rend la détection très compliquée.

La troisième image concerne le littoral (450×289). Les zones modifiées sont très petites, concentrées sur la limite de la rivière, ce qui rend la détection difficile.

Le quatrième ensemble de données concerne les zones modifiées générées par les terres agricoles nouvellement irriguées, il s'agit du jeu de données de San Francisco, acquis par le capteur ERS-2SAR. La taille de l'image originale est de 7749×7713 pixels. Les images ont été capturées en août 2003 et mai 2004, respectivement, nous choisissons une taille de région typique (256×256 pixels) pour vérifier l'efficacité de la méthode proposée. Les deux images sont montrées dans la dernière ligne de la Figure 4. 5(a) -(c).

L'évaluation des performances des algorithmes de détection de changements peut être mesurée sur la base de la comparaison visuelle et numérique. La comparaison visuelle utilise la carte de détection binaire finale, dans laquelle les pixels noirs et les pixels blancs représentent les zones inchangées et modifiées, respectivement, et l'image de vérité au sol (Ground Truth).

Une comparaison numérique dont les paramètres sont constitués de cinq critères classiques, à savoir : les faux négatifs (FN) se réfèrent au nombre de pixels modifiés qui sont détectés par erreur comme inchangés, les faux positifs (FP) désignent le nombre de pixels inchangés qui

sont mal détectés, l'erreur globale (OE) qui indique le nombre total d'erreurs, la classification correcte en pourcentage (PCC) et le coefficient Kappa (Kappa).

$$OE = FP + FN \quad (4.17)$$

$$PCC = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.18)$$

$$Kappa = \frac{PCC - PRE}{1 - PRE} \quad (4.19)$$

Où,

$$PRE = \frac{(TP + FP) \times Nc + (FN + TN) \times Nu}{(TP + TN + FP + FN)^2} \quad (4.20)$$

Les vrais positifs (TP) font référence au nombre de pixels correctement prédits comme modifiés. Les vrais négatifs (TN) font référence au nombre de pixels correctement détectés comme inchangés. Nc and Nu font référence au nombre de pixels appartenant respectivement à la classe modifiée et inchangée.

4.3.2 Analyse des paramètres

4.3.2.1 Test de la taille du patch (k)

La taille du voisinage dans l'extraction des caractéristiques est un paramètre important, il est choisi comme paramètre de test car les informations contextuelles contribuent de manière considérable à la précision de la détection des changements. Ici, k indique la taille d'un exemple de patch d'image provenant des images d'origine. Le PCC est utilisé ici comme critère de validation.

Comme le montre la Figure 4.4, nous avons fixé k à 11,13,15,17. Les quatre courbes montrent que la valeur de PCC tend à se détériorer avec l'agrandissement de k. Si $k > 11$ les caractéristiques du quartier ne sont pas représentatives. Par conséquent, $k = 11$ est la meilleure option car la méthode proposée offre de meilleures performances.




Figure 4. 4: Relation entre la taille du patch (k) et le critère d'évaluation PCC

4.3.2.2 Étude du nombre d'échantillons d'entraînement

Le Tableau 4.1 présente la comparaison des performances du Mdp-CapsNet avec les autres méthodes sur le jeu de données Yellow River A. Comme le montre le Tableau 4.1, différents nombres d'échantillons d'entraînement ont été sélectionnés : 400, 600, 800 et 1000 dans le but de refléter les avantages du réseau de capsules qui prend en compte les hiérarchies spatiales entre les entités, nécessitant moins d'échantillons d'entraînement. Il est clair que la précision des autres méthodes diminue considérablement lorsque le nombre d'échantillons est inférieur à 600.

En revanche, les deux méthodes basées sur les réseaux de capsules sont moins affectées par le nombre d'échantillons, elles obtiennent de bonnes performances, soit en utilisant un très petit nombre d'échantillons d'apprentissage, une partie des échantillons d'apprentissage ou tous les échantillons d'apprentissage.

Tableau 4.1: Relation entre le nombre d'échantillon de formation et le critère d'évaluation PCC sur l'ensemble de données Yellow River A

ECHANTILLONS DE FORMATION	400	600	800	1000
MÉTHODE				
PCANet	92.20	93.36	93.78	94.66
DNN	92.18	92.68	93.71	94.82
CNN	92.86	93.45	94.65	95.36
CWNN	93.71	94.72	95.02	95.78
MS-CapsNet	94.98	95.28	95.65	96.00
Mdp-CapsNet	95.42	95.78	96.12	97.48

4.3.2.3 Influence du module d'attention

Le processus de conception du module d'attention et son efficacité sont vérifiés expérimentalement dans cette partie. Le nouveau module d'attention dispose de deux sous-modules séquentiels : canal et spatial, et peut facilement se connecter à la sortie des trois couches convolutives. Il a été adopté pour obtenir des caractéristiques saillantes et efficaces. Nous comparons d'abord trois approches de stratégies de mise en commun : max pooling, average pooling et l'utilisation combinée des deux méthodes, qui sont adoptées dans un module d'attention spatiale. Ensuite, nous avons étudié l'effet de l'ablation du module d'attention sur les performances de détection de changements. Nous avons donc implémenté notre architecture sans attention de module (w/o AFC). D'après les résultats numériques des critères d'évaluation inclus dans le Tableau 4.2, on peut observer que le module d'attention avec n'importe quelle méthode de pooling peut augmenter les performances de la détection de changements. Les valeurs PCC ont été améliorées de 1,59, 0,77, 1,21 et 0,66 par l'architecture proposée sur les quatre ensembles de données, respectivement. Il est évident que le module d'attention est bénéfique pour améliorer la performance de la détection de changements. Ces résultats impliquent également les avantages de choisir la mise en commun moyenne (average pooling) par rapport aux deux autres méthodes.

4.3.2.4 Influence de la fonction de perte

Dans cette partie, l'efficacité de l'utilisation de la fonction de perte marginale focale est démontrée empiriquement. Selon les résultats du Tableau 4.2, nous pouvons observer que la méthode proposée avec la fonction de perte marginale focale obtient les meilleurs résultats que ceux obtenus avec la fonction de perte originale sur les quatre données, respectivement. Cela signifie que la fonction de perte marginale focale choisie est très appropriée pour résoudre le déséquilibre des échantillons dans le problème de détection de changements, ce qui prouve que nos améliorations sont efficaces.

Tableau 4. 2: Influence du modèle d'attention et de la fonction de perte

MÉTHODE	Yellow River A	Yellow River B	Coastline	San Francisco
Architecture complète	97.48	99.26	99.88	99.02
Architecture + Maxpool	96.46	98.89	99.11	98.78
Architecture+ Avg +Max	96.59	98.94	99.28	98.45
W/o Module Attention	95.89	98.49	98.67	98.36
Avec fonction de perte originale	96.12	98.75	99.16	98.83
Avec fonction de perte proposée	97.48	99.26	99.88	99.02

4.3.3 Comparaison des performances de l'approche proposée avec d'autres algorithmes de détection de changements

Afin d'évaluer la performance de l'approche de détection de changements proposée, nous la comparons à diverses méthodes étroitement liées sur les quatre ensembles de données, notamment le PCA-Net non supervisé [158], le réseau neuronal profond DNN [112], deux méthodes basées sur CNN [75] et CWNN [89], et enfin Ms-CapsNet [151].

Résultats expérimentaux sur l'ensemble de données Yellow River A et Yellow River B : le Tableau 4.3 présente les résultats de l'évaluation obtenus par les différentes méthodes. Comme le montre le Tableau 4.3, l'algorithme proposé obtient les meilleurs résultats en termes de valeurs de paramètres OE, PCC et Kappa, ce qui est en accord avec les résultats visuels (Figure 4. 5), la carte finale de détection de changements obtenue est beaucoup plus proche de l'image de vérité au sol. Les autres algorithmes de comparaison ont des valeurs FN faibles et des valeurs FP élevées, ce qui signifie que ces algorithmes sont inefficaces dans les scénarios de bruit de speckle.

Grâce à leur représentation profonde des caractéristiques, les méthodes basées sur CNN peuvent générer moins de bruit et plus de régions modifiées terminées, ce qui montre que les deux méthodes sont plus performantes dans une certaine mesure.

Pour les méthodes PCANet et DNN, il est difficile de générer des résultats satisfaisants et leur carte de changement finale tend à être assez bruyante, ce qui se traduit par une valeur élevée de l'OE. Bien que la méthode MS-CapsNet ait amélioré la précision des résultats concurrentiels de détection de changement par rapport à la méthode Mdp-CapsNet, l'extraction de caractéristiques basée sur une couche de convolution scalaire rend ses performances médiocres.

Tableau 4. 3: Résultats de la détection de changements sur l'ensemble de données Yellow River

CRITÈRES	Yellow River A DATA SET					Yellow River B DATA SET				
	FP	FN	OE	PCC (%)	KC (%)	FP	FN	OE	PCC (%)	KC (%)
PCANet	2435	1533	3968	94.66	82.43	2942	493	3435	96.14	71.55
DNN	1644	2144	3780	94.82	82.75	561	668	1229	98.62	88.86
CNN	1640	1700	3340	95.36	85.28	400	580	980	98.74	89.09
CWNN	1520	1600	3120	95.78	85.59	538	620	1158	98.69	88.98
MS-CapsNet	1173	1798	2971	96.00	86.25	468	407	875	99.02	91.22
Mdp-CapsNet	800	1057	1857	97.48	88.90	336	360	696	99.26	92.12

➤ **Résultats expérimentaux sur l'ensemble de données Coastline :**

En ce qui concerne l'ensemble de données Coastline, il est vraiment difficile de détecter les changements, car les régions modifiées sont assez petites et susceptibles d'être inondées par le bruit de speckle.

Bien que les méthodes basées sur CNN aient obtenu des résultats acceptables en termes de précision, elles ont néanmoins manqué certains détails modifiés.

En termes d'effets visuels, les cartes de changements binaires finales obtenues par PCANet sont les pires car elles présentent de nombreux points de bruit. (Figure 4. 5).

En termes d'analyse quantitative, comme le montre le Tableau 4.4, les résultats obtenus par la méthode proposée sont les meilleurs de tous, le rendement Kappa est de 99,88%, ce qui est supérieur à 97,29%, 97,47%, 98,75%, 98,14% généré par le PCANet, DNN, CNN, CWNN, respectivement. La méthode MS-CapsNet donne toujours des résultats compétitifs.

Dans l'ensemble, le Mdp-CapsNet proposé est meilleur et révèle des résultats plus expressifs.

➤ **Résultats expérimentaux du jeu de données San Francisco :**

Les résultats de la détection de changements obtenus sur le jeu de données de San Francisco sont illustrés à la Figure 4.5. Les indicateurs quantitatifs correspondants sont présentés dans le Tableau 4.4. D'un point de vue visuel, nous pouvons constater que la carte de changement finale générée par notre méthode est beaucoup plus proche de l'image de la vérité -terrain que les autres procédés.

En termes d'analyse quantitative, la méthode proposée présente moins de pixels mal classés et améliore la précision du modèle, obtenant ainsi les meilleurs résultats d'évaluation en termes de valeurs de coefficient OE, PCC et Kappa.

Tableau 4. 4: Résultats de la détection de changements sur l'ensemble de données Coastline et San Francisco

CRITÈRES MÉTHODE	Coastline DATA SET					San Francisco DATA SET				
	FP	FN	OE	PCC (%)	KC (%)	FP	FN	OE	PCC (%)	KC (%)
PCANet	16	630	646	97.29	77.86	316	480	796	98.47	90.65
DNN	44	588	632	97.47	78.65	330	460	790	98.52	90.74
CNN	49	389	438	98.75	81.72	318	440	758	98.85	91.16
CWNN	48	482	530	98.14	80.83	347	417	764	98.64	90.81
MS-CapsNet	40	339	379	99.47	82.56	320	403	723	98.82	91.87
Mdp-CapsNet	25	300	325	99.88	85.35	275	364	639	99.02	92.17




Figure 4. 5: Résultats visualisés de diverses méthodes de détection de changements sur quatre ensembles de données.

- | | | |
|--------------------------|----------------------------|---|
| a) Image obtenue à t_1 | b) Image obtenue à t_2 | c) Cartes de changement de vérité-terrain |
| d) Résultat de PCANet | e) Résultat par DNN | f) Résultat de CNN |
| g) Résultat CWNN | h) Résultat de Mmc CapsNet | i) Résultat de Mdp-CapsNet |

4.4 CONCLUSION

Dans ce chapitre, un algorithme innovant de détection de changements est proposé pour la détection de changements en imagerie SAR basé sur le réseau de capsules. Le codage

multidimensionnel parallèle de la capsule est utilisé pour en apprendre davantage sur des caractéristiques riches et robustes. Une fonction de perte marginale-focale est introduite afin de concentrer l'apprentissage sur les échantillons mal classés, ce qui améliore considérablement la robustesse et la précision du réseau. De plus, nous avons conçu un module d'attention, ce qui a pour résultat que les caractéristiques les plus relatives avec des informations sémantiques de haut niveau ont été extraites et les informations bruyantes et distrayantes ont été supprimées. Les résultats expérimentaux sur quatre ensembles de données SAR réels démontrent le plus grand potentiel de la méthode proposée.

Dans les travaux futurs, nous prévoyons d'explorer la performance du réseau de capsules par rapport à d'autres images de télédétection telles que les images SAR polarimétriques.

Chapitre 5

Détection de changements en imagerie PolSAR

Le présent chapitre s'inspire de l'article intitulé :

Attoui, S., & Najah, S. (2022). A Deep Learning Framework for Polarimetric SAR Change Detection Using Capsule Network. International Journal of Computer and Information Engineering, 16(5), 196-200.

Actuellement, de nombreuses solutions de pointe destinées pour les tâches d'analyse d'images SAR/POLSAR telles que la classification et la détection de changement s'appuient sur les réseaux de neurones convolutifs (ConvNets). L'un des principaux éléments des réseaux de neurones convolutifs réussis est la disponibilité de quantités massives de données de formation. La construction et l'annotation de grands ensembles de données pour résoudre les problèmes de classification et de détection des images SAR constituent désormais un goulet d'étranglement pour de nombreuses applications.

Dans le chapitre précédent, nous avons démontré expérimentalement que les propriétés d'équivariance des CapsNets réduisent les fortes exigences en données, et sont donc très prometteuses pour l'analyse d'images SAR. En particulier, nous avons démontré la capacité de généralisation accrue des CapsNets par rapport aux ConvNets face à la quantité limitée de données et au déséquilibre des classes. Bien que l'efficacité des CapsNets dans l'analyse d'images de télédétection ait été vérifiée expérimentalement, son application dans les tâches de détection de changement est très rare.

Dans ce contexte, ce chapitre présente un nouveau cadre de détection de changements pour les images PolSAR, dont le réseau de capsules a été appliqué, il s'appuie sur les résultats du chapitre précédent, et fait **l'objet de recherches futures**.

5.1 Introduction

La technologie de la télédétection est de plus en plus omniprésente et opérationnelle, elle englobe des méthodes et des technologies permettant de récupérer des informations sur la

surface terrestre mesurées à distance à l'aide d'un rayonnement électromagnétique réfléchi ou émis par la surface de la Terre [159], ce qui permet de résoudre de nombreux problèmes liés à la surveillance et à la cartographie de la Terre.

Ces dernières années, les images SAR ont reçu de plus en plus d'attention et l'intérêt de les comprendre d'un point de vue multidimensionnel et multilook a considérablement augmenté, de tels systèmes sont connus sous le nom de « SAR polarimétrique » (PolSAR).

Différent des données SAR à polarisation unique, les données PolSAR, imagerie multicanal et multiparamètre, contiennent à la fois des informations de phase et d'amplitude provenant des retours radar transmis dans deux polarisations différentes, ce qui signifie que davantage d'informations biophysiques et géophysiques améliorées sur la cible peuvent être extraites qui le rend très précieux et pratique pour surveiller la Terre superficielle [160] [13] [161]. De nombreuses applications ont montré la supériorité des techniques radar entièrement polarimétrique, y compris la surveillance des terres et l'évaluation de l'hydrologie (humidité du sol, délimitation des inondations), l'estimation de la biomasse forestière, la cartographie de la couverture terrestre et de l'utilisation des terres, la surveillance des glaces de mer, le climat océanique et la surveillance côtière [162] [163].

L'un des sujets les plus importants du SAR polarimétrique est la détection de changements, qui vise à identifier les zones modifiées résultant de l'évolution de la surface de la Terre, grâce à des images multi-temporelles acquises pour la même zone géographique à des dates d'observation distinctes, c'est une tâche très difficile, non seulement en raison du problème de speckle, mais également en raison de la texture complexe, qui apparaît généralement très hétérogène. Diverses techniques ont été proposées dans la détection de changements en imagerie PolSAR, la plupart reposent sur des représentations d'entités artisanales, nécessitent beaucoup de connaissances spécialisées et de calculs complexes, d'où une capacité de représentation limitée pour décrire des informations de changement complexes et de haut niveau. Cependant, ces méthodes ne peuvent pas répondre aux besoins et attentes actuels en matière de surveillance dynamique de l'environnement.

Une extraction précise et rapide d'informations pertinentes à partir d'ensembles de données massifs pour la tâche de détection de changements est devenue un problème urgent, en particulier avec les progrès rapides des techniques de télédétection où de nombreux nouveaux problèmes et défis continuent d'émerger.

Au cours des dernières années, les méthodes d'apprentissage en profondeur, capables d'extraire efficacement les caractéristiques invariantes et discriminantes dans les tâches de la vision par ordinateur, ont suscité un vif intérêt dans les communautés de télédétection. Malgré leurs applications étendues et leurs grands avantages, ils sont rarement appliqués à la tâche de détection de changement dans les images SAR polarimétriques.

Inspirés par ces techniques florissantes, et afin de tirer profit des avantages et des résultats de notre deuxième contribution, ce chapitre vise à présenter un nouveau cadre de détection de changements basé sur l'apprentissage en profondeur pour l'imagerie radar à synthèse d'ouverture polarimétrique (PolSAR).

5.2 Détection de changements en imagerie PolSAR

5.2.1 Travaux connexes

Le SAR polarimétrique (PolSAR) fournit potentiellement une capacité de détection accrue, par rapport au SAR à polarisation unique. Diverses techniques ont été proposées, parmi lesquelles : le test d'hypothèse [164], le clustering flou [71] et la modélisation statistique [165], des mesures théoriques de l'information [166], Hotelling–Lawley tests [166], détection de changement avec post-classification [167].

Le processus de la détection de changements est théoriquement enraciné dans la théorie des tests d'hypothèses et la proposition de mesures statistiques de similarité.

Le premier travail sur les statistiques de test pour la détection de changements dans les données PolSAR a été réalisé par Conradsen et al. [168], qui ont proposé une méthodologie basée sur le test du rapport de vraisemblance généralisé (LRT) pour l'égalité de deux matrices de covariance complexes et qui ont appliqué avec succès une distribution d'échantillonnage asymptotique pour la statistique LRT. Cette approche, aussi appelée test de Bartlett, a été comparée avec les tests alternatifs de rapport de contraste et d'ellipticité dans le travail présenté par Kersten et al. [169].

Plus tard, Akbari et al. [166], ont proposé un détecteur de changement impliquant la Trace de Hotelling-Lawley (HLT), qui asymptotiquement, suit la distribution de Fisher-Snedecor (FS). La méthode peut être vue comme une version matricielle du test du rapport d'intensité, où le HLT est utilisé pour contraster deux matrices de covariance complexes et produire une valeur scalaire, à laquelle un seuil peut être appliqué. Des expériences sur des ensembles de données

PolSAR simulées et réelles démontrent que la méthode de détection de changements proposée donne des taux de détection et des taux d'erreur comparables au test du rapport de vraisemblance généralisé et peut surpasser le test de Bartlett dans certains scénarios.

Une détection pour les séries chronologiques PolSAR basée sur le test du rapport de vraisemblance (TRV) pour l'homogénéité de plusieurs matrices variance-covariance complexes a été proposé dans [170]. Plusieurs études ont utilisé des outils d'information théoriques en tant qu'étape de pré-traitement pour détecter les changements dans les images PolSAR. Les pixels environnants sont modélisés selon une distribution donnée et les mesures de distance sont appliquées en vue d'obtenir une statistique comparative. Mercier et al. [62], ont proposé une nouvelle mesure de similarité, basée sur l'évolution des statistiques locales de l'image entre deux dates, pour la détection automatique des changements. Une telle mesure a été dérivée en tenant compte de la divergence (ou distance) symétrisée de Kullback-Leibler (KL) entre les extensions de la série Edgeworth pour deux éléments distincts de la distribution K du système Pearson [171] pour les données SAR d'intensité. Erten et al. [172], ont proposé une méthode basée sur l'information mutuelle issue de la théorie de l'information pour quantifier la similarité cohérente entre les images radar à synthèse d'ouverture (SAR) multicanaux temporelles.

Dans [173], Une nouvelle technique est présentée pour mettre automatiquement en évidence les changements dans des images de télédétection multitemporelles fortement hétérogènes, la mesure de Kullback-Leibler est améliorée au moyen d'une régression quantile basée sur la copule pour générer des mesures de changement local. Nascimento et al. [174], ont établi des tests d'hypothèse basés sur multiples mesures de distance entre les distributions G^0 .

Une méthode de détection de changements basée sur la statistique de trace Hotelling-Lawley et le seuil d'erreur minimum a été proposé par Ghanbari et al. [175]. Cette méthode a été mise en œuvre en deux étapes principales : Dans la première étape de la méthode, la statistique de trace Hotelling-Lawley (HLT) est appliquée pour mesurer la similarité de deux matrices de covariance multilook. À la suite de cette étape, une image statistique de test scalaire est générée. Ensuite, dans la deuxième étape, un algorithme généralisé de seuillage d'erreur minimum de Kittler et Illingworth (K&I) est développé pour effectuer sur l'image statistique de test et discriminer entre les zones modifiées et inchangées.

Bien qu'il existe de nombreuses méthodes, elles présentent généralement des limitations :

- Certaines des méthodes proposées sont mises en œuvre en deux phases (c.-à-d. prédiction et décision), dont la combinaison peut avoir une incidence sur l'exactitude de l'algorithme de détection de changement.
- La plupart des techniques précédentes reposent sur des représentations d'entités artisanales, exigeant de vastes connaissances spécialisées et des calculs complexes, d'où une capacité de représentation limitée pour décrire des informations de changement complexes et de haut niveau.

Toutefois, ces méthodes ne peuvent répondre aux besoins et aux attentes actuels en matière de contrôle dynamique de l'environnement. L'apprentissage en profondeur a suscité un intérêt considérable de la part des communautés mondiales des sciences de la Terre.

Avec un développement fulgurant, de nombreuses architectures d'apprentissage profond sont bien connues dans divers domaines, tels que le traitement d'images, la reconnaissance vocale, le traitement du langage naturel etc. Ces architectures comprennent, entre autres, les réseaux de neurones convolutifs (CNN), les réseaux de croyance profonde (DBN) et les réseaux d'empilement profond. Les réseaux de neurones convolutifs ont attiré une attention intensive et se sont avérées pour de nombreuses applications de télédétection, y compris la détection de changements.

Liu et al. [144] ont développé une nouvelle version du réseau de neurones convolutifs (CNN), nommé CNN local restreint (LRCNN). Dans la formation du réseau CNN/LRCNN, la propriété polarimétrique de l'image SAR est pleinement utilisée à la place des pixels étiquetés manuellement. Une mesure de similarité pour les données SAR polarimétriques a été proposée, et plusieurs images de différence en couches (LDI) d'images SAR polarimétriques ont été générées. Ensuite, les LDI sont transformés en LDI améliorés discriminants (DELDI). CNN/LRCNN a été formé pour modéliser ces DELDI par un préapprentissage de régression, puis un ajustement de classification est effectué avec certains pixels pseudo marqués obtenus à partir de DELDI. Enfin, sur la base du modèle entraîné optimisé, une carte de changement a été obtenue. Seydi et al. [176] ont proposé un nouveau cadre de détection de changement basé sur le réseau neuronal convolutif (CNN). Le réseau de détection de changements proposé basé sur CNN contient trois canaux parallèles : le premier et le second canal, respectivement, extraient des caractéristiques profondes sur les images originales, et le troisième canal se concentre sur l'extraction de caractéristiques profondes de changement basées sur la différenciation et l'implantation de caractéristiques profondes.

Bien que les réseaux neuronaux convolutifs (CNN) aient prouvé leur supériorité dans le domaine de la détection de changement en raison de leur puissante capacité d'apprentissage des fonctionnalités, il y a encore des lacunes qui limitent leur utilisation.

Le déséquilibre des ensembles de données, l'indisponibilité de grands ensembles de données, sont des problèmes qui rendent le domaine difficile.

Plus récemment, le réseau de capsule (CapsNet) a été proposé pour surmonter les limitations des réseaux de neurones convolutifs. Le réseau de capsules (CapsNet) a montré de grandes performances dans de nombreuses applications d'imagerie, et il a obtenu des résultats plus compétitifs que les CNN tels que l'analyse d'images de télédétection et la reconnaissance de cible. Le réseau de capsules (CapsNet) peut contenir plus d'informations sur les objets, ce qui est avantageux pour représenter plusieurs mécanismes de diffusion des couvertures terrestres, car une capsule est définie comme un vecteur composé d'un groupe de neurones pour caractériser les attributs polarimétriques.

À notre connaissance, il n'a pas été constaté que les chercheurs utilisaient CapsNet pour détecter les changements dans les images PolSAR. Le travail présenté dans ce chapitre s'appuie sur les résultats du chapitre précédent, et fait l'objet de recherches futures.

5.2.2 Formulation du problème

5.2.2.1 Représentation des images PolSAR

La grandeur fondamentale mesurée par un radar polarimétrique à chaque pixel et à chaque fréquence est la matrice de diffusion [S] [160]. [S] représente toutes les informations des caractéristiques de diffusion de la cible et elle peut être exprimé comme :

$$S = \begin{bmatrix} S_{hh} & S_{hv} \\ S_{vh} & S_{vv} \end{bmatrix} \quad (5.1)$$

La matrice de diffusion [S] contient toutes les informations polarimétriques, avec les entrées $S_{hh}, S_{hv}, S_{vh}, S_{vv}$. S_{xy} , représente les coefficients de diffusion complexes, où x fait référence à la polarisation de l'antenne d'émission et y à celle de l'antenne de réception. *h* et *v* désignent les polarisations horizontale et verticale, respectivement. Dans le cas de la rétrodiffusion monostatique, la même antenne assure l'émission et la réception, les termes hors diagonale de [S] sont égaux, $S_{hv} = S_{vh}$.

En supposant que la condition de réciprocité cible est satisfaite, la rétrodiffusion d'un système SAR polarimétrique monostatique est caractérisée par le vecteur de diffusion complexe, k_L , de dimension $d = 3$, donné par :

$$k_L = [S_{hh}, \sqrt{2} S_{hv}, S_{vv}]^T \quad (5.2)$$

Les vecteurs de diffusion peuvent également être transformés en matrices de covariance d'échantillons à plusieurs regards, et la matrice de covariance de L-look est caractérisée par [177] :

$$C = \langle k_L \cdot k_L^{*t} \rangle \quad (5.3)$$

Où* est le complexe conjugué.

5.2.2.2 Aperçu de la méthode proposée

Soit deux images A et B, deux images SAR polarimétriques de taille égale, acquises à des instants différents t_1 et t_2 sur la même zone géographique.

$I_1 = \{A(i, j); 1 \leq i \leq M, 1 \leq j \leq N\}$ et $I_2 = \{B(i, j); 1 \leq i \leq M, 1 \leq j \leq N\}$, où M et N sont le nombre de lignes et de colonnes des images, respectivement.

Notre objectif est de générer une carte de changement binaire : $I(i, j) \in \{0,1\}$, qui représente les informations modifiées, où 1 indique que la position (i, j) est modifiée et 0 indique que la position (i, j) est inchangée.

La méthode proposée fonctionne de manière non supervisée qui implique les étapes suivantes :

- ✓ **Étape 1** : prétraitement de l'image.
- ✓ **Étape 2** : étape de pré-classification basée sur la mesure de similarité et sur une technique simple et efficace de seuillage basé sur l'histogramme généralisé. L'étape vise à diviser DI (image de différence) en classes modifiées et inchangées.
- ✓ **Étape 3** : formation du Modèle CapsNet : les échantillons de formation sont sélectionnés au hasard à partir de DI.
- ✓ **Étape 4** : Classification des pixels modifiés et inchangés : les pixels du DI sont classés par le CapsNet formé pour obtenir la carte de modification finale.

▪ Le prétraitement des données est une étape très importante dans les méthodes de détection de changement PolSAR. Le multilooking, le co-registation d'images [178] et le filtrage de speckle [179] sont les principales techniques de traitement d'images PolSAR.

Les images PolSAR sont toujours affectées par le bruit de speckle, rendant le processus de détection plus difficile. Plusieurs méthodes de filtrage sont disponibles, nous avons opté pour le filtre de Lee raffiné [180] avec une taille de noyau de 5, qui permet de préserver les détails des bords aussi bien en contraste faible qu'en contraste élevé. L'augmentation de la taille du filtre rend l'image plus floue et réduit le bruit, en revanche, la diminution de la taille du filtre préserve davantage la structure de l'image mais produit une image plus bruyante. La fenêtre 5 x 5 a été choisie comme un compromis et fixée de manière à ce que les variations entre les images soient dues uniquement aux changements de la mesure de dissemblance.

Une correction géométrique est appliquée pour le co-registation des images à des fins de comparaison et d'appariement.

- L'étape suivante consiste à générer une image de différence (DI), produite sur la base d'une mesure de similarité. Chaque valeur dans DI indique la différence entre deux pixels dans les deux images d'entrée et les zones modifiées sont déterminées en fonction de DI.

La mesure de distance matricielle est basée sur l'hypothèse que les données PolSAR suivent la distribution complexe de Wishart mise à l'échelle. Nous exploitons une version symétrique de la distance de Wishart révisée (SRW) comme mesure de similarité, plus de détails sur la distance SRW peuvent être trouvés dans [178] .

Pour deux pixels i et j , qui peuvent être caractérisés par la matrice de covariance C_i et C_j , la distance SRW est comme :

$$DI = d_{SRW}(C_i, C_j) = \frac{1}{2} \left(\text{tr}(C_i^{-1}C_j + C_j^{-1}C_i) \right) - p \quad (5.4)$$

Où Tr désigne la trace d'une matrice.

- Après avoir obtenu DI, compte tenu de l'efficacité du Technique de seuillage d'histogramme généralisé (GHT) [181], la technique de seuillage est utilisée pour classer les pixels de DI en deux groupes : la classe modifiée Ω_c , la classe inchangée Ω_u . Les pixels appartenant aux deux classes ont la forte probabilité d'être modifiés et inchangés, ils sont sélectionnés comme échantillons d'apprentissage. Les caractéristiques de voisinage des pixels échantillons (sélectionnés au hasard) appartenant aux deux types de classes sont générées.

- Extraction de caractéristiques à plusieurs échelles : le noyau de convolution de la même taille ne peut pas capturer efficacement suffisamment d'informations sur les caractéristiques, cela nous a incité à trouver une façon plus efficace d'extraire les caractéristiques.

Le CapsNet proposé contient un module d'extraction de caractéristiques multi-échelles avant la couche capsule primaire qui est conçu pour garantir l'extraction de caractéristiques plus riches. Comme le montre la Figure 5.2, la carte d'entités en entrée, elle sera traitée de quatre manières et regroupera les résultats pour obtenir la carte finale des nouvelles fonctionnalités. Le modèle comprend une convolution $1 * 1$, deux noyaux de convolution de tailles différentes et un module de regroupement moyen. L'utilisation de la convolution $1 * 1$ vise à réduire la dimensionnalité, en diminuant le nombre de cartes de caractéristiques tout en conservant leurs caractéristiques saillantes, réduisant ainsi la complexité de calcul. Les différents noyaux de convolution possèdent des champs récepteurs différents, leur combinaison permet d'obtenir des fonctionnalités plus riches qu'un noyau de convolution de taille unique. Le module de regroupement peut aussi jouer un rôle dans certaines extractions caractéristiques, et ce rôle diffère du rôle de convolution. Enfin, en utilisant le CapsNet formé, les pixels du DI sont classés pour acquérir la carte de changement final.




Figure 5. 1: La méthode de détection de changements proposée




Figure 5. 2: Module d'extraction de caractéristiques multi-échelles

5.2.2.3 Résultats expérimentaux

Pour évaluer l'efficacité de la méthode proposée, l'ensemble de données réel utilisée se compose de deux images polarimétriques complètes UAVSAR co-enregistrées en bande L. Les deux images appartiennent à la ville de Los Angeles, en Californie, acquises par le Jet Propulsion Laboratory/National Aeronautics and Space Administration UAVSAR (1,26 GHz) le 23 avril 2009 et le 11 mai 2015. Les images Pauli-RGB (Rouge : $|HH-VV|$; Vert : $2|HV|$; Bleu : $|HH+VV|$) et l'image vérité de terrain sont illustrés sur la Figure.5.3.

Comme critères d'évaluation, les faux positifs (FP), les faux négatifs (FN), le pourcentage de classification correcte (PCC), les erreurs globales (OE) et le coefficient Kappa (KC) sont adoptés.



Figure 5. 3: Images Los Angeles Pauli-RVB.
(a) Image prise en 23 avril 2009. (b) Image prise 11 mai 2015. (c) Image vérité de terrain.



Figure 5. 4: Résultats visualisés sur l'Image Los Angeles.
(a) Résultat par la méthode proposée (b) Résultat par CNN

Tableau 5. 1: Résultats de la détection de changements sur le jeu de donnée Los Angeles

Method	FN	FP	OE	PCC (%)	KC (%)
CNN	1645	1768	3413	93.36	81.28
Méthode proposé	800	1157	1957	97,08	88,90

Dans cette étude, nous avons comparé uniquement les performances du réseau de capsule avec le réseau neuronal convolutif (CNN). Les résultats quantitatifs et les résultats visuels sont affichés dans le Tableau 5.1 et la Figure.5.4, respectivement. Nous pouvons observer que la méthode proposée révèle des résultats plus expressifs. D'un point de vue visuel, nous pouvons voir que la carte de changement finale générée par notre méthode est beaucoup plus proche de l'image de la vérité – terrain que le processus CNN qui tend à être plutôt bruyant et affligé d'une valeur FP élevée.

5.3 CONCLUSION

Dans ce travail, un réseau de capsules amélioré est proposé pour la détection de changements d'images PolSAR. Nous avons introduit un module d'extraction de caractéristiques multi-échelles dans le réseau qui assure que les fonctionnalités plus riches sont transmises dans la capsule. Par rapport aux méthodes CNN, la méthode proposée présente de bonnes performances en termes de comparaison visuelle et quantitative.

Les recherches futures mettront l'accent sur l'amélioration du rendement du réseau de capsules et l'application accrue aux ensembles de données d'images PolSAR.

Conclusion générale et recherches futures

Synthèse et conclusion

À la suite des activités anthropiques et naturelles, la surface de la Terre change constamment avec le temps. L'identification précise et opportune des changements est essentielle pour mieux gérer et surveiller plus efficacement les ressources naturelles et les changements environnementaux.

Les progrès de la télédétection ont permis aux plates-formes de collecter une variété croissante de données, qui sont devenues une ressource importante pour détecter et surveiller les changements à la surface de la terre. Le radar SAR (Synthetic Aperture Radar) peut observer la surface de la Terre à tout moment et dans toutes les conditions météorologiques, ce qui en fait une excellente alternative pour la télédétection de la Terre et des applications allant de l'exploration spatiale à la détection des changements.

Au cours des dernières décennies, des efforts considérables ont été déployés pour développer des méthodes automatiques de détection de changement à l'aide d'imageries SAR. L'apprentissage automatique est actuellement considéré comme l'ensemble d'approche le plus prometteur et en constante évolution.

Bien que l'apprentissage en profondeur soit une solution prometteuse, la détection de changement en imagerie SAR est déjà un problème complexe et diversifié, et son application fait face à plusieurs restrictions et problèmes, notamment le manque de données de formation de vérité de terrain, le bruit de speckle multiplicatif inhérent et le déséquilibre des classes.

C'est dans ce contexte que cette thèse a mis l'accent sur l'amélioration de la performance et de la précision des modèles de détection de changement en imagerie SAR basés sur l'apprentissage en profondeur. Une analyse exhaustive des techniques de détection de changement, des défis et des limites a fait l'objet d'une analyse et d'une discussion.

Les résultats obtenus et les discussions abordées tout au long de la thèse ont apporté des contributions significatives pour faire progresser l'application de l'apprentissage profond à la détection de changement en imagerie SAR. Sur la base des résultats expérimentaux, les

approches proposées peuvent être mise en œuvre pour effectuer la cartographie de la couverture terrestre et la détection des tendances de changement dans la zone d'étude.

Dans notre travail initial, un modèle de génération d'échantillon virtuel est utilisé pour mieux former le réseau en augmentant les échantillons de diversité appropriés, offrant ainsi une solution alternative au problème de la rareté des données étiquetées. Une attention a également été accordée à la réduction de l'impact de la présence de speckle, à cette fin, une pré-classification a été proposée basée sur la reconstruction morphologique et le filtrage des membres.

Les Capsule Networks ou CapsNets ont ouvert la voie à une nouvelle dynamique dans le développement des neurones artificiels, leur utilisation dans des domaines tels que l'imagerie SAR illustre un avenir prometteur.

Notre deuxième objectif de recherche était de tirer profit du réseau de capsules comme solution alternative, qui peut atteindre les mêmes performances que les techniques basées sur l'apprentissage profond mais avec moins de données de formation. Notre principale motivation à cet égard était l'absence de recherche dans la littérature sur son application aux images SAR. L'architecture proposée vise à améliorer la capacité du réseau à extraire des fonctionnalités plus riches et plus robustes, elle adopte un module d'attention visant à atténuer les interférences du bruit de speckle. Dans le but de réduire l'impact des échantillons déséquilibrés lors de l'optimisation du réseau, une fonction de perte focale marginale a été utilisée pour attirer l'attention sur les échantillons mal classés.

Les résultats obtenus tout au long de la thèse reflètent l'état de l'art concernant le développement de méthodes de détection automatique basée sur l'apprentissage profond. Dans ce contexte, la proposition des réseaux de capsules est une alternative intéressante, nous espérons que les résultats obtenus aideront les chercheurs à formuler de nouvelles idées et à combler les lacunes de la recherche liées aux réseaux de capsules.

Recommandations et travaux futures

- ✓ En raison d'un manque d'accès aux données polarimétriques multitemporelles, Cette thèse a porté principalement sur des données SAR monofréquence et mono-polarisées. Bien que des résultats satisfaisants aient été obtenus pour cartographier les changements

de la couverture terrestre, l'introduction d'autres sources d'information, comme les images SAR polarimétriques multitemporelles, constituerait également une voie importante vers l'avenir, en dépit de leurs nombreux avantages, ces données représentent un nouveau type de défi qui exige l'élaboration de changements appropriés, des améliorations notables peuvent être apportées à l'algorithme de détection de changements présenté au chapitre 5.

- ✓ Compte tenu des limites des images SAR ou optiques, nous explorons la possibilité d'améliorer la qualité de la détection de changements en fusionnant les données SAR et optiques.
- ✓ Enfin, au vu des difficultés rencontrées dans l'accès aux données SAR/PolSAR, il serait recommandé que des jeux de données soient disponibles pour une utilisation à grande échelle par les chercheurs et les organisations intéressés par le développement de solutions pour la détection de changement.

BIBLIOGRAPHIE

- [1] B. Hou, Q. Wei, Y. Zheng, et S. Wang, « Unsupervised Change Detection in SAR Image Based on Gauss-Log Ratio Image Fusion and Compressed Projection », *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 7, n° 8, p. 3297-3317, août 2014, doi: [10.1109/JSTARS.2014.2328344](https://doi.org/10.1109/JSTARS.2014.2328344).
- [2] S. Wang, L. Jiao, et S. Yang, « SAR Images Change Detection Based on Spatial Coding and Nonlocal Similarity Pooling », *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 9, n° 8, p. 3452-3466, août 2016, doi: [10.1109/JSTARS.2016.2547638](https://doi.org/10.1109/JSTARS.2016.2547638).
- [3] S. Saha, F. Bovolo, et L. Bruzzone, « Building Change Detection in VHR SAR Images via Unsupervised Deep Transcoding », *IEEE Trans. Geosci. Remote Sens.*, vol. 59, n° 3, p. 1917-1929, mars 2021, doi: [10.1109/TGRS.2020.3000296](https://doi.org/10.1109/TGRS.2020.3000296).
- [4] V. Akbari, A. Doulgeris, et T. Eltoft, « Monitoring Glacier Changes Using Multitemporal Multipolarization SAR Images », *IEEE Trans. Geosci. Remote Sens.*, vol. 52, août 2013, doi: [10.1109/TGRS.2013.2275203](https://doi.org/10.1109/TGRS.2013.2275203).
- [5] H. Zhang, H. Lin, et Y. Li, « Impacts of Feature Normalization on Optical and SAR Data Fusion for Land Use/Land Cover Classification », *IEEE Geosci. Remote Sens. Lett.*, vol. 12, n° 5, p. 1061-1065, mai 2015, doi: [10.1109/LGRS.2014.2377722](https://doi.org/10.1109/LGRS.2014.2377722).
- [6] D. Amitrano, G. Di Martino, A. Iodice, D. Riccio, et G. Ruello, « Unsupervised Rapid Flood Mapping Using Sentinel-1 GRD SAR Images », *IEEE Trans. Geosci. Remote Sens.*, vol. 56, n° 6, p. 3290-3299, juin 2018, doi: [10.1109/TGRS.2018.2797536](https://doi.org/10.1109/TGRS.2018.2797536).
- [7] P. P. de Bem, O. A. de Carvalho Junior, R. Fontes Guimarães, et R. A. Trancoso Gomes, « Change Detection of Deforestation in the Brazilian Amazon Using Landsat Data and Convolutional Neural Networks », *Remote Sens.*, vol. 12, n° 6, Art. n° 6, janv. 2020, doi: [10.3390/rs12060901](https://doi.org/10.3390/rs12060901).
- [8] P. Wang, H. Zhang, et V. M. Patel, « SAR Image Despeckling Using a Convolutional Neural Network », *IEEE Signal Process. Lett.*, vol. 24, n° 12, p. 1763-1767, déc. 2017, doi: [10.1109/LSP.2017.2758203](https://doi.org/10.1109/LSP.2017.2758203).
- [9] C. Silva-Perez, A. Marino, J. M. Lopez-Sanchez, et I. Cameron, « Multitemporal Polarimetric SAR Change Detection for Crop Monitoring and Crop Type Classification », *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 14, p. 12361-12374, 2021, doi: [10.1109/JSTARS.2021.3130186](https://doi.org/10.1109/JSTARS.2021.3130186).
- [10] A. Elfadaly, N. Abate, N. Masini, et R. Lasaponara, « SAR Sentinel 1 Imaging and Detection of Palaeo-Landscape Features in the Mediterranean Area », *Remote Sens.*, vol. 12, n° 16, Art. n° 16, janv. 2020, doi: [10.3390/rs12162611](https://doi.org/10.3390/rs12162611).
- [11] C. Oliver et S. Quegan, *Understanding Synthetic Aperture Radar Images*, 2nd edition. SciTech Publishing, 2004.
- [12] I. G. Cumming et F. H. Wong, *Digital Processing of Synthetic Aperture Radar Data: Algorithms and Implementation*. Boston: Artech House Print on Demand, 2005.
- [13] C. Elachi et J. J. van Zyl, *Introduction to the Physics and Techniques of Remote Sensing*. John Wiley & Sons, 2006.
- [14] D. Massonnet et J.-C. Souyris, *Imaging with Synthetic Aperture Radar*, 1st Edition. EPFL Press, 2008. doi: [10.1201/9781439808139](https://doi.org/10.1201/9781439808139).
- [15] L. Swart, R. Hanssen, S. Usai, F. Civiele, et A. Geodesie, « Spectral Filtering and Oversampling for Radar Interferometry », mars 2001.
- [16] Maître, Henri, « Traitement Des Images De Radar À Synthèse D'ouverture (Rso) | Rakuten ». <https://fr.shopping.rakuten.com/offer/buy/48849139/Maitre-Henri-Traitement-Des-Images-De-Radar-A-Synthese-D-ouverture-Rso-Livre.html>
- [17] J. C. Curlander et R. N. McDonough, *Synthetic Aperture Radar: Systems and Signal Processing*. Wiley, 1992.
- [18] C. A. Wiley, « Pulsed doppler radar methods and apparatus », US3196436A, 20 juillet 1965. <https://patents.google.com/patent/US3196436A/en>
- [19] O. Antropov, « Land cover and forest mapping in boreal zone using polarimetric and interferometric SAR data: Dissertation », Dissertation, Aalto University, Espoo, 2014.

- [20] Y.-Q. Jin et F. Xu, *Polarimetric Scattering and SAR Information Retrieval*. John Wiley & Sons, 2013.
- [21] G. Sinclair, « The Transmission and Reception of Elliptically Polarized Waves », *Proc. IRE*, vol. 38, n° 2, p. 148-151, févr. 1950, [doi: 10.1109/JRPROC.1950.230106](https://doi.org/10.1109/JRPROC.1950.230106).
- [22] J.-S. Lee et E. Pottier, *Polarimetric Radar Imaging: From Basics to Applications*. CRC Press, 2017.
- [23] R. Touzi, W. M. Boerner, J. S. Lee, et E. Lueneburg, « A review of polarimetry in the context of synthetic aperture radar: concepts and information extraction », *Can. J. Remote Sens.*, vol. 30, n° 3, p. 380-407, janv. 2004, [doi: 10.5589/m04-013](https://doi.org/10.5589/m04-013).
- [24] S. R. Cloude et E. Pottier, « A review of target decomposition theorems in radar polarimetry », *IEEE Trans. Geosci. Remote Sens.*, vol. 34, n° 2, p. 498-518, mars 1996, [doi: 10.1109/36.485127](https://doi.org/10.1109/36.485127).
- [25] S. R. Cloude et E. Pottier, « An Entropy Based Classification Scheme for Land Applications of Polarimetric SAR ». *IEEE Transactions on Geoscience and Remote Sensing*, 35, 68-78, 1997. [https://www.scirp.org/\(S\(czeh2tfqyw2orz553k1w0r45\)\)/reference/referencespapers.aspx?referenceid=2218819](https://www.scirp.org/(S(czeh2tfqyw2orz553k1w0r45))/reference/referencespapers.aspx?referenceid=2218819)
- [26] S.-W. Chen, W. Xuesong, S.-P. Xiao, et M. Sato, « Advanced Polarimetric Target Decomposition », 2018, p. 43-106. [doi: 10.1007/978-981-10-7269-7_2](https://doi.org/10.1007/978-981-10-7269-7_2).
- [27] S. Cloude, *Polarisation: Applications in Remote Sensing*. OUP Oxford, 2010.
- [28] E. Krogager, « New decomposition of the radar target scattering matrix », *Electron. Lett.*, vol. 26, n° 18, p. 1525-1527, août 1990, [doi: 10.1049/el:19900979](https://doi.org/10.1049/el:19900979).
- [29] W. L. Cameron et L. K. Leung, « Feature motivated polarization scattering matrix decomposition », in *IEEE International Conference on Radar*, mai 1990, p. 549-557. [doi: 10.1109/RADAR.1990.201088](https://doi.org/10.1109/RADAR.1990.201088).
- [30] S. R. Cloude, « Polarimetry: the characterisation of polarisation effects in EM scattering », d_ph, University of Birmingham, 1987. <https://etheses.bham.ac.uk/id/eprint/5440/>
- [31] A. Singh, « Review Article Digital change detection techniques using remotely-sensed data », *Int. J. Remote Sens.*, vol. 10, n° 6, p. 989-1003, juin 1989, [doi: 10.1080/01431168908903939](https://doi.org/10.1080/01431168908903939).
- [32] D. Lu, P. Mausel, E. Brondizio, et E. Moran, « Change detection techniques », *Int. J. Remote Sens.*, vol. 25, n° 12, p. 2365-2401, juin 2004, [doi: 10.1080/0143116031000139863](https://doi.org/10.1080/0143116031000139863).
- [33] B. Zitová et J. Flusser, « Image registration methods: a survey », *Image Vis. Comput.*, vol. 21, n° 11, p. 977-1000, oct. 2003, [doi: 10.1016/S0262-8856\(03\)00137-9](https://doi.org/10.1016/S0262-8856(03)00137-9).
- [34] J. Queiroz-Neto, M. Campos, B. Nelson, et J. Pio, « Automatic Geometric and Radiometric Registration of Landsat-TM Images Using Mutual Information. », janv. 2004, p. 343-360.
- [35] Y. Wu, W. Ma, M. Gong, L. Su, et L. Jiao, « A Novel Point-Matching Algorithm Based on Fast Sample Consensus for Image Registration », *IEEE Geosci. Remote Sens. Lett.*, vol. 12, n° 1, p. 43-47, janv. 2015, [doi: 10.1109/LGRS.2014.2325970](https://doi.org/10.1109/LGRS.2014.2325970).
- [36] Y. Afaq et A. Manocha, « Analysis on change detection techniques for remote sensing applications: A review », *Ecol. Inform.*, vol. 63, p. 101310, juill. 2021, [doi: 10.1016/j.ecoinf.2021.101310](https://doi.org/10.1016/j.ecoinf.2021.101310).
- [37] S. E. Franklin et P. T. Giles, « Radiometric processing of aerial and satellite remote-sensing imagery », *Comput. Geosci.*, vol. 21, n° 3, p. 413-423, avr. 1995, [doi: 10.1016/0098-3004\(94\)00085-9](https://doi.org/10.1016/0098-3004(94)00085-9).
- [38] X. Wan, J. Liu, S. Li, J. Dawson, et H. Yan, « An Illumination-Invariant Change Detection Method Based on Disparity Saliency Map for Multitemporal Optical Remotely Sensed Images », *IEEE Trans. Geosci. Remote Sens.*, vol. 57, n° 3, p. 1311-1324, mars 2019, [doi: 10.1109/TGRS.2018.2865961](https://doi.org/10.1109/TGRS.2018.2865961).
- [39] O. A. Ajadi, F. J. Meyer, et P. W. Webley, « Change Detection in Synthetic Aperture Radar Images Using a Multiscale-Driven Approach », *Remote Sens.*, vol. 8, n° 6, Art. n° 6, juin 2016, [doi: 10.3390/rs8060482](https://doi.org/10.3390/rs8060482).
- [40] J. Lee, L. Jurkevich, P. Dewaele, P. Wambacq, et A. Oosterlinck, « Speckle filtering of synthetic aperture radar images: A Review », *Remote Sens. Rev.*, vol. 8, févr. 1994, [doi: 10.1080/02757259409532206](https://doi.org/10.1080/02757259409532206).

- [41] V. S. Frost, J. A. Stiles, K. S. Shanmugan, et J. C. Holtzman, « A Model for Radar Images and Its Application to Adaptive Digital Filtering of Multiplicative Noise », *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. PAMI-4, n° 2, p. 157-166, mars 1982, [doi: 10.1109/TPAMI.1982.4767223](https://doi.org/10.1109/TPAMI.1982.4767223).
- [42] S. Parrilli, M. Poderico, C. V. Angelino, et L. Verdoliva, « A Nonlocal SAR Image Denoising Algorithm Based on LLMMSE Wavelet Shrinkage », *IEEE Trans. Geosci. Remote Sens.*, vol. 50, n° 2, p. 606-616, févr. 2012, [doi: 10.1109/TGRS.2011.2161586](https://doi.org/10.1109/TGRS.2011.2161586).
- [43] G. Moser et S. B. Serpico, « Generalized minimum-error thresholding for unsupervised change detection from SAR amplitude imagery », *IEEE Trans. Geosci. Remote Sens.*, vol. 44, n° 10, p. 2972-2982, oct. 2006, [doi: 10.1109/TGRS.2006.876288](https://doi.org/10.1109/TGRS.2006.876288).
- [44] L. Bruzzone et S. B. Serpico, « An iterative technique for the detection of land-cover transitions in multitemporal remote-sensing images », *IEEE Trans. Geosci. Remote Sens.*, vol. 35, n° 4, p. 858-867, juill. 1997, [doi: 10.1109/36.602528](https://doi.org/10.1109/36.602528).
- [45] D. Cozzolino, L. Verdoliva, G. Scarpa, et G. Poggi, « Nonlocal CNN SAR Image Despeckling », *Remote Sens.*, vol. 12, n° 6, Art. n° 6, janv. 2020, [doi: 10.3390/rs12061006](https://doi.org/10.3390/rs12061006).
- [46] R. Liu, Z. Cheng, L. Zhang, et J. Li, « Remote Sensing Image Change Detection Based on Information Transmission and Attention Mechanism », *IEEE Access*, vol. 7, p. 156349-156359, 2019, [doi: 10.1109/ACCESS.2019.2947286](https://doi.org/10.1109/ACCESS.2019.2947286).
- [47] R. J. Radke, S. Andra, O. Al-Kofahi, et B. Roysam, « Image change detection algorithms: a systematic survey », *IEEE Trans. Image Process.*, vol. 14, n° 3, p. 294-307, mars 2005, [doi: 10.1109/TIP.2004.838698](https://doi.org/10.1109/TIP.2004.838698).
- [48] D. Haboudane et E. M. Bahri, « Deforestation Detection and Monitoring in Cedar Forests of the Moroccan Middle-Atlas Mountains », in *2007 IEEE International Geoscience and Remote Sensing Symposium*, juill. 2007, p. 4327-4330. [doi: 10.1109/IGARSS.2007.4423809](https://doi.org/10.1109/IGARSS.2007.4423809).
- [49] M. Gong, Z. Zhou, et J. Ma, « Change Detection in Synthetic Aperture Radar Images based on Image Fusion and Fuzzy Clustering », *IEEE Trans. Image Process.*, vol. 21, n° 4, p. 2141-2151, avr. 2012, [doi: 10.1109/TIP.2011.2170702](https://doi.org/10.1109/TIP.2011.2170702).
- [50] D. Yacouba, G. Hu, et X. Wen, « Applications of Remote Sensing in Land Use/Land Cover Change Detection in Puer and Simao Counties, Yunnan Province », *J Am Sci*, vol. 5, janv. 2009.
- [51] U. Bayarsaikhan, B. Boldgiv, K.-R. Kim, K.-A. Park, et D. Lee, « Change detection and classification of land cover at Hustai National Park in Mongolia », *Int. J. Appl. Earth Obs. Geoinformation*, vol. 11, n° 4, p. 273-280, août 2009, [doi: 10.1016/j.jag.2009.03.004](https://doi.org/10.1016/j.jag.2009.03.004).
- [52] A. A. Torahi et S. C. Rai, « Land Cover Classification and Forest Change Analysis, Using Satellite Imagery-A Case Study in Dehdez Area of Zagros Mountain in Iran », *J. Geogr. Inf. Syst.*, vol. 3, n° 1, Art. n° 1, janv. 2011, [doi: 10.4236/jgis.2011.31001](https://doi.org/10.4236/jgis.2011.31001).
- [53] G. M. Foody, « Status of land cover classification accuracy assessment », *Remote Sens. Environ.*, vol. 80, n° 1, p. 185-201, avr. 2002, [doi: 10.1016/S0034-4257\(01\)00295-4](https://doi.org/10.1016/S0034-4257(01)00295-4).
- [54] L. Bruzzone, « Automatic analysis of the difference image for unsupervised change detection », *IEEE Trans. Geosci. Remote Sens.*, vol. 38, p. 1171-1182, juin 2000, [doi: 10.1109/36.843009](https://doi.org/10.1109/36.843009).
- [55] P. Olofsson, G. M. Foody, M. Herold, S. V. Stehman, C. E. Woodcock, et M. A. Wulder, « Good practices for estimating area and assessing accuracy of land change », *Remote Sens. Environ.*, vol. 148, p. 42-57, mai 2014, [doi: 10.1016/j.rse.2014.02.015](https://doi.org/10.1016/j.rse.2014.02.015).
- [56] V. Sadeghi, F. Farnood Ahmadi, et H. Ebadi, « A new fuzzy measurement approach for automatic change detection using remotely sensed images », *Measurement*, vol. 127, p. 1-14, oct. 2018, [doi: 10.1016/j.measurement.2018.05.097](https://doi.org/10.1016/j.measurement.2018.05.097).
- [57] H. Zhuang, K. Deng, et H. Fan, « Filtering Approach Based on Voter Model and Spatial-Contextual Information to the Binary Change Map in SAR Images », *J. Indian Soc. Remote Sens.*, vol. 45, n° 5, p. 733-741, oct. 2017, [doi: 10.1007/s12524-016-0639-5](https://doi.org/10.1007/s12524-016-0639-5).
- [58] H. Zhuang, H. Fan, K. Deng, et G. Yao, « A Spatial-Temporal Adaptive Neighborhood-Based Ratio Approach for Change Detection in SAR Images », *Remote Sens.*, vol. 10, n° 8, Art. n° 8, août 2018, [doi: 10.3390/rs10081295](https://doi.org/10.3390/rs10081295).

- [59] Y. Bazi, L. Bruzzone, et F. Melgani, « An unsupervised approach based on the generalized Gaussian model to automatic change detection in multitemporal SAR images », *IEEE Trans. Geosci. Remote Sens.*, vol. 43, n° 4, p. 874-887, avr. 2005, doi: [10.1109/TGRS.2004.842441](https://doi.org/10.1109/TGRS.2004.842441).
- [60] Y. Zheng, L. Jiao, H. Liu, X. Zhang, B. Hou, et S. Wang, « Unsupervised saliency-guided SAR image change detection », *Pattern Recognit.*, vol. 61, p. 309-326, janv. 2017, doi: [10.1016/j.patcog.2016.07.040](https://doi.org/10.1016/j.patcog.2016.07.040).
- [61] M. Gong, Y. Cao, et Q. Wu, « A Neighborhood-Based Ratio Approach for Change Detection in SAR Images », *IEEE Geosci. Remote Sens. Lett.*, vol. 9, n° 2, p. 307-311, mars 2012, doi: [10.1109/LGRS.2011.2167211](https://doi.org/10.1109/LGRS.2011.2167211).
- [62] J. Inglada et G. Mercier, « A New Statistical Similarity Measure for Change Detection in Multitemporal SAR Images and Its Extension to Multiscale Change Analysis », *IEEE Trans. Geosci. Remote Sens.*, vol. 45, n° 5, p. 1432-1445, mai 2007, doi: [10.1109/TGRS.2007.893568](https://doi.org/10.1109/TGRS.2007.893568).
- [63] Y. Bazi, L. Bruzzone, et F. Melgani, « Automatic identification of the number and values of decision thresholds in the log-ratio image for change detection in SAR images », *IEEE Geosci. Remote Sens. Lett.*, vol. 3, n° 3, p. 349-353, juill. 2006, doi: [10.1109/LGRS.2006.869973](https://doi.org/10.1109/LGRS.2006.869973).
- [64] J. Ma, M. Gong, et Z. Zhou, « Wavelet Fusion on Ratio Images for Change Detection in SAR Images », *IEEE Geosci. Remote Sens. Lett.*, vol. 9, n° 6, p. 1122-1126, nov. 2012, doi: [10.1109/LGRS.2012.2191387](https://doi.org/10.1109/LGRS.2012.2191387).
- [65] H. Zhuang, Z. Tan, K. Deng, et G. Yao, « Adaptive Generalized Likelihood Ratio Test for Change Detection in SAR Images », *IEEE Geosci. Remote Sens. Lett.*, vol. 17, n° 3, p. 416-420, mars 2020, doi: [10.1109/LGRS.2019.2922198](https://doi.org/10.1109/LGRS.2019.2922198).
- [66] J. Wang, X. Yang, X. Yang, L. Jia, et S. Fang, « Unsupervised change detection between SAR images based on hypergraphs », *ISPRS J. Photogramm. Remote Sens.*, vol. 164, p. 61-72, juin 2020, doi: [10.1016/j.isprsjprs.2020.04.007](https://doi.org/10.1016/j.isprsjprs.2020.04.007).
- [67] S. Quegan, T. Le Toan, J. J. Yu, F. Ribbes, et N. Floury, « Multitemporal ERS SAR analysis applied to forest mapping », *IEEE Trans. Geosci. Remote Sens.*, vol. 38, n° 2, p. 741-753, mars 2000, doi: [10.1109/36.842003](https://doi.org/10.1109/36.842003).
- [68] W. Dierking et H. Skriver, « Change detection for thematic mapping by means of airborne multitemporal polarimetric SAR imagery », *IEEE Trans. Geosci. Remote Sens.*, vol. 40, n° 3, p. 618-636, mars 2002, doi: [10.1109/TGRS.2002.1000322](https://doi.org/10.1109/TGRS.2002.1000322).
- [69] M. Gong, Y. Li, L. Jiao, M. Jia, et L. Su, « SAR change detection based on intensity and texture changes », *ISPRS J. Photogramm. Remote Sens.*, vol. 93, p. 123-135, juill. 2014, doi: [10.1016/j.isprsjprs.2014.04.010](https://doi.org/10.1016/j.isprsjprs.2014.04.010).
- [70] Z. Yetgin, « Unsupervised Change Detection of Satellite Images Using Local Gradual Descent », *IEEE Trans. Geosci. Remote Sens.*, vol. 50, n° 5, p. 1919-1929, mai 2012, doi: [10.1109/TGRS.2011.2168230](https://doi.org/10.1109/TGRS.2011.2168230).
- [71] A. Ghosh, N. S. Mishra, et S. Ghosh, « Fuzzy clustering algorithms for unsupervised change detection in remote sensing images », *Inf. Sci.*, vol. 181, n° 4, p. 699-715, févr. 2011, doi: [10.1016/j.ins.2010.10.016](https://doi.org/10.1016/j.ins.2010.10.016).
- [72] M. Kesikoğlu, Ü. Atasever, et C. Özkan, « Unsupervised change detection in satellite images using Fuzzy C-Means Clustering and principal component analysis », *ISPRS - Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. XL-7/W2, p. 129-132, oct. 2013, doi: [10.5194/isprsarchives-XL-7-W2-129-2013](https://doi.org/10.5194/isprsarchives-XL-7-W2-129-2013).
- [73] H.-C. Li, T. Celik, N. Longbotham, et W. J. Emery, « Gabor Feature Based Unsupervised Change Detection of Multitemporal SAR Images Based on Two-Level Clustering », *IEEE Geosci. Remote Sens. Lett.*, vol. 12, n° 12, p. 2458-2462, déc. 2015, doi: [10.1109/LGRS.2015.2484220](https://doi.org/10.1109/LGRS.2015.2484220).
- [74] D. Tian et M. Gong, « A novel edge-weight based fuzzy clustering method for change detection in SAR images », *Inf. Sci.*, vol. 467, p. 415-430, oct. 2018, doi: [10.1016/j.ins.2018.08.015](https://doi.org/10.1016/j.ins.2018.08.015).
- [75] Y. Li, C. Peng, Y. Chen, L. Jiao, L. Zhou, et R. Shang, « A Deep Learning Method for Change Detection in Synthetic Aperture Radar Images », *IEEE Trans. Geosci. Remote Sens.*, vol. 57, n° 8, p. 5751-5763, août 2019, doi: [10.1109/TGRS.2019.2901945](https://doi.org/10.1109/TGRS.2019.2901945).

- [76] M. Gong, H. Yang, et P. Zhang, « Feature learning and change feature classification based on deep learning for ternary change detection in SAR images », *ISPRS J. Photogramm. Remote Sens.*, vol. 129, p. 212-225, juill. 2017, doi: [10.1016/j.isprsjprs.2017.05.001](https://doi.org/10.1016/j.isprsjprs.2017.05.001).
- [77] G. E. Hinton, S. Osindero, et Y.-W. Teh, « A Fast Learning Algorithm for Deep Belief Nets », *Neural Comput.*, vol. 18, n° 7, p. 1527-1554, juill. 2006, doi: [10.1162/neco.2006.18.7.1527](https://doi.org/10.1162/neco.2006.18.7.1527).
- [78] Yong Du, W. Wang, et L. Wang, « Hierarchical recurrent neural network for skeleton based action recognition », in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, juin 2015, p. 1110-1118. doi: [10.1109/CVPR.2015.7298714](https://doi.org/10.1109/CVPR.2015.7298714).
- [79] Y. LeCun, K. Kavukcuoglu, et C. Farabet, « Convolutional networks and applications in vision », in *Proceedings of 2010 IEEE International Symposium on Circuits and Systems*, mai 2010, p. 253-256. doi: [10.1109/ISCAS.2010.5537907](https://doi.org/10.1109/ISCAS.2010.5537907).
- [80] X. Zhang, Y. Liang, C. Li, N. Huyan, L. Jiao, et H. Zhou, « Recursive Autoencoders-Based Unsupervised Feature Learning for Hyperspectral Image Classification », *IEEE Geosci. Remote Sens. Lett.*, vol. 14, n° 11, p. 1928-1932, nov. 2017, doi: [10.1109/LGRS.2017.2737823](https://doi.org/10.1109/LGRS.2017.2737823).
- [81] B. Hou, Y. Wang, et Q. Liu, « Change Detection Based on Deep Features and Low Rank », *IEEE Geosci. Remote Sens. Lett.*, vol. 14, n° 12, p. 2418-2422, déc. 2017, doi: [10.1109/LGRS.2017.2766840](https://doi.org/10.1109/LGRS.2017.2766840).
- [82] Y. Gao, F. Gao, J. Dong, et S. Wang, « Transferred Deep Learning for Sea Ice Change Detection From Synthetic-Aperture Radar Images », *IEEE Geosci. Remote Sens. Lett.*, vol. 16, n° 10, p. 1655-1659, oct. 2019, doi: [10.1109/LGRS.2019.2906279](https://doi.org/10.1109/LGRS.2019.2906279).
- [83] Y. Duan, F. Liu, L. Jiao, P. Zhao, et L. Zhang, « SAR Image segmentation based on convolutional-wavelet neural network and markov random field », *Pattern Recognit*, vol. 64, p. 255-267, 2017, doi: [10.1016/j.patcog.2016.11.015](https://doi.org/10.1016/j.patcog.2016.11.015).
- [84] H. Chen, C. Wu, B. Du, L. Zhang, et L. Wang, « Change Detection in Multisource VHR Images via Deep Siamese Convolutional Multiple-Layers Recurrent Neural Network », *IEEE Trans. Geosci. Remote Sens.*, vol. 58, n° 4, p. 2848-2864, avr. 2020, doi: [10.1109/TGRS.2019.2956756](https://doi.org/10.1109/TGRS.2019.2956756).
- [85] T. Zhan, M. Gong, X. Jiang, et M. Zhang, « Unsupervised Scale-Driven Change Detection With Deep Spatial-Spectral Features for VHR Images », *IEEE Trans. Geosci. Remote Sens.*, vol. 58, n° 8, p. 5653-5665, août 2020, doi: [10.1109/TGRS.2020.2968098](https://doi.org/10.1109/TGRS.2020.2968098).
- [86] F. Samadi, G. Akbarizadeh, et H. Kaabi, « Change Detection in SAR Images using Deep Belief Network: a New Training Approach based on Morphological Images », *IET Image Process.*, vol. 13, oct. 2019, doi: [10.1049/iet-ipr.2018.6248](https://doi.org/10.1049/iet-ipr.2018.6248).
- [87] J. Geng, H. Wang, J. Fan, et X. Ma, « Change detection of SAR images based on supervised contractive autoencoders and fuzzy clustering », in *2017 International Workshop on Remote Sensing with Intelligent Processing (RSIP)*, mai 2017, p. 1-3. doi: [10.1109/RSIP.2017.7958819](https://doi.org/10.1109/RSIP.2017.7958819).
- [88] C. Shorten et T. M. Khoshgoftaar, « A survey on Image Data Augmentation for Deep Learning », *J. Big Data*, vol. 6, n° 1, p. 60, juill. 2019, doi: [10.1186/s40537-019-0197-0](https://doi.org/10.1186/s40537-019-0197-0).
- [89] F. Gao, X. Wang, Y. Gao, J. Dong, et S. Wang, « Sea Ice Change Detection in SAR Images Based on Convolutional-Wavelet Neural Networks », *IEEE Geosci. Remote Sens. Lett.*, vol. 16, n° 8, p. 1240-1244, août 2019, doi: [10.1109/LGRS.2019.2895656](https://doi.org/10.1109/LGRS.2019.2895656).
- [90] F. Gao, J. Dong, B. Li, Q. Xu, et C. Xie, « Change detection from synthetic aperture radar images based on neighborhood-based ratio and extreme learning machine », *J. Appl. Remote Sens.*, vol. 10, p. 046019, déc. 2016, doi: [10.1117/1.JRS.10.046019](https://doi.org/10.1117/1.JRS.10.046019).
- [91] F. Gao, X. Wang, J. Dong, et S. Wang, « SAR Image Change Detection Based on Frequency Domain Analysis and Random Multi-Graphs », *J. Appl. Remote Sens.*, vol. 12, déc. 2017, doi: [10.1117/1.JRS.12.016010](https://doi.org/10.1117/1.JRS.12.016010).
- [92] T. Zhan, M. Gong, X. Jiang, et S. Li, « Log-Based Transformation Feature Learning for Change Detection in Heterogeneous Images », *IEEE Geosci. Remote Sens. Lett.*, vol. 15, n° 9, p. 1352-1356, sept. 2018, doi: [10.1109/LGRS.2018.2843385](https://doi.org/10.1109/LGRS.2018.2843385).
- [93] S. Chitroub, A. Houacine, et B. Sansal, « Statistical characterisation and modelling of SAR images », *Signal Process.*, vol. 82, n° 1, p. 69-92, janv. 2002, doi: [10.1016/S0165-1684\(01\)00158-X](https://doi.org/10.1016/S0165-1684(01)00158-X).

- [94] M. Dalla Mura, S. Prasad, F. Pacifici, P. Gamba, J. Chanussot, et J. A. Benediktsson, « Challenges and Opportunities of Multimodality and Data Fusion in Remote Sensing », *Proc. IEEE*, vol. 103, n° 9, p. 1585-1601, sept. 2015, [doi: 10.1109/JPROC.2015.2462751](https://doi.org/10.1109/JPROC.2015.2462751).
- [95] P. Coppin, I. Jonckheere, K. Nackaerts, B. Muys, et E. Lambin, « Review Article Digital change detection methods in ecosystem monitoring: a review », *Int. J. Remote Sens.*, vol. 25, n° 9, p. 1565-1596, mai 2004, [doi: 10.1080/0143116031000101675](https://doi.org/10.1080/0143116031000101675).
- [96] L. Huang, Y. Fang, X. Zuo, et X. Yu, « Automatic Change Detection Method of Multitemporal Remote Sensing Images Based on 2D-Otsu Algorithm Improved by Firefly Algorithm », *J. Sens.*, vol. 2015, p. 1-8, juill. 2015, [doi: 10.1155/2015/327123](https://doi.org/10.1155/2015/327123).
- [97] Y. Bazi, L. Bruzzone, et F. Melgani, « Image thresholding based on the EM algorithm and the generalized Gaussian distribution », *Pattern Recognit.*, vol. 40, n° 2, p. 619-634, févr. 2007, [doi: 10.1016/j.patcog.2006.05.006](https://doi.org/10.1016/j.patcog.2006.05.006).
- [98] B. Xiong, Q. Chen, Y. Jiang, et G. Kuang, « A Threshold Selection Method Using Two SAR Change Detection Measures Based on the Markov Random Field Model », *IEEE Geosci. Remote Sens. Lett.*, vol. 9, n° 2, p. 287-291, mars 2012, [doi: 10.1109/LGRS.2011.2166149](https://doi.org/10.1109/LGRS.2011.2166149).
- [99] Q. Zhao et J. C. Principe, « Support vector machines for SAR automatic target recognition », *IEEE Trans. Aerosp. Electron. Syst.*, vol. 37, n° 2, p. 643-654, avr. 2001, [doi: 10.1109/7.937475](https://doi.org/10.1109/7.937475).
- [100] O. Kechagias-Stamatis et N. Aouf, « Fusing Deep Learning and Sparse Coding for SAR ATR », *IEEE Trans. Aerosp. Electron. Syst.*, vol. 55, n° 2, p. 785-797, avr. 2019, [doi: 10.1109/TAES.2018.2864809](https://doi.org/10.1109/TAES.2018.2864809).
- [101] R. Ressel, A. Frost, et S. Lehner, « A Neural Network-Based Classification for Sea Ice Types on X-Band SAR Images », *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 8, n° 7, p. 3672-3680, juill. 2015, [doi: 10.1109/JSTARS.2015.2436993](https://doi.org/10.1109/JSTARS.2015.2436993).
- [102] G. Forkuor, C. Conrad, M. Thiel, T. Ullmann, et E. Zoungrana, « Integration of Optical and Synthetic Aperture Radar Imagery for Improving Crop Mapping in Northwestern Benin, West Africa », *Remote Sens.*, vol. 6, n° 7, Art. n° 7, juill. 2014, [doi: 10.3390/rs6076472](https://doi.org/10.3390/rs6076472).
- [103] G. Akbarizadeh, « A New Statistical-Based Kurtosis Wavelet Energy Feature for Texture Recognition of SAR Images », *IEEE Trans. Geosci. Remote Sens.*, vol. 50, n° 11, p. 4358-4368, nov. 2012, [doi: 10.1109/TGRS.2012.2194787](https://doi.org/10.1109/TGRS.2012.2194787).
- [104] Z. Tirandaz et G. Akbarizadeh, « A Two-Phase Algorithm Based on Kurtosis Curvelet Energy and Unsupervised Spectral Regression for Segmentation of SAR Images », *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 9, n° 3, p. 1244-1264, mars 2016, [doi: 10.1109/JSTARS.2015.2492552](https://doi.org/10.1109/JSTARS.2015.2492552).
- [105] A. Eisapour Moghaddam, G. Akbarizadeh, et H. Kaabi, « Automatic detection and segmentation of blood vessels and pulmonary nodules based on a line tracking method and generalized linear regression model », *Signal Image Video Process.*, vol. 13, n° 3, p. 457-464, avr. 2019, [doi: 10.1007/s11760-018-01413-0](https://doi.org/10.1007/s11760-018-01413-0).
- [106] Z. Tirandaz, G. Akbarizadeh, et H. Kaabi, « PolSAR image segmentation based on feature extraction and data compression using Weighted Neighborhood Filter Bank and Hidden Markov random field-expectation maximization », *Measurement*, vol. 153, p. 107432, mars 2020, [doi: 10.1016/j.measurement.2019.107432](https://doi.org/10.1016/j.measurement.2019.107432).
- [107] N. Ahmadi et G. Akbarizadeh, « Iris tissue recognition based on GLDM feature extraction and hybrid MLPNN-ICA classifier », *Neural Comput. Appl.*, vol. 32, n° 7, p. 2267-2281, avr. 2020, [doi: 10.1007/s00521-018-3754-0](https://doi.org/10.1007/s00521-018-3754-0).
- [108] L. Deng *et al.*, « Recent Advances in Deep Learning for Speech Research at Microsoft », mai 2013, <https://www.microsoft.com/en-us/research/publication/recent-advances-in-deep-learning-for-speech-research-at-microsoft/>
- [109] H. Magdy et X.-C. Yin, « Classification of EgyptSat-1 Images Using Deep Learning Methods », *Int. J. Sens. Wirel. Commun. Control*, vol. 09, févr. 2019, [doi: 10.2174/2210327909666190207153858](https://doi.org/10.2174/2210327909666190207153858).
- [110] D. C. Ciresan, U. Meier, J. Masci, L. M. Gambardella, et J. Schmidhuber, « Flexible, High Performance Convolutional Neural Networks for Image Classification », p. 6.

- [111] D. Prokhorov, « A convolutional learning system for object classification in 3-D Lidar data », *IEEE Trans. Neural Netw.*, vol. 21, n° 5, p. 858-863, mai 2010, [doi: 10.1109/TNN.2010.2044802](https://doi.org/10.1109/TNN.2010.2044802).
- [112] M. Gong, J. Zhao, J. Liu, Q. Miao, et L. Jiao, « Change Detection in Synthetic Aperture Radar Images Based on Deep Neural Networks », *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 27, n° 1, p. 125-138, janv. 2016, [doi: 10.1109/TNNLS.2015.2435783](https://doi.org/10.1109/TNNLS.2015.2435783).
- [113] F. Sharifzadeh, G. Akbarizadeh, et Y. Seifi Kavian, « Ship Classification in SAR Images Using a New Hybrid CNN–MLP Classifier », *J. Indian Soc. Remote Sens.*, vol. 47, n° 4, p. 551-562, avr. 2019, [doi: 10.1007/s12524-018-0891-y](https://doi.org/10.1007/s12524-018-0891-y).
- [114] Q. Wang *et al.*, « GETNET: A General End-to-end Two-dimensional CNN Framework for Hyperspectral Image Change Detection », *IEEE Trans. Geosci. Remote Sens.*, vol. 57, n° 1, p. 3-13, janv. 2019, [doi: 10.1109/TGRS.2018.2849692](https://doi.org/10.1109/TGRS.2018.2849692).
- [115] J. C. Dunn, « A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact Well-Separated Clusters », *J. Cybern.*, févr. 1973, [doi: 10.1080/01969727308546046](https://doi.org/10.1080/01969727308546046).
- [116] J. C. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms*, 1st edition. New York: Plenum Press, 1981.
- [117] M. N. Ahmed, S. M. Yamany, N. Mohamed, A. A. Farag, et T. Moriarty, « A modified fuzzy c-means algorithm for bias field estimation and segmentation of MRI data », *IEEE Trans. Med. Imaging*, vol. 21, n° 3, p. 193-199, mars 2002, [doi: 10.1109/42.996338](https://doi.org/10.1109/42.996338).
- [118] S. Chen et D. Zhang, « Robust image segmentation using FCM with spatial constraints based on new kernel-induced distance measure », *IEEE Trans. Syst. Man Cybern. Part B Cybern.*, vol. 34, n° 4, p. 1907-1916, août 2004, [doi: 10.1109/TSMCB.2004.831165](https://doi.org/10.1109/TSMCB.2004.831165).
- [119] L. Szilagyi, Z. Benyo, S. M. Szilagyi, et H. S. Adam, « MR brain image segmentation using an enhanced fuzzy C-means algorithm », in *Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (IEEE Cat. No.03CH37439)*, sept. 2003, vol. 1, p. 724-726 Vol.1. [doi: 10.1109/IEMBS.2003.1279866](https://doi.org/10.1109/IEMBS.2003.1279866).
- [120] W. Cai, S. Chen, et D. Zhang, « Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation », *Pattern Recognit.*, vol. 40, n° 3, p. 825-838, mars 2007, [doi: 10.1016/j.patcog.2006.07.011](https://doi.org/10.1016/j.patcog.2006.07.011).
- [121] S. Krinidis et V. Chatzis, « A Robust Fuzzy Local Information C-Means Clustering Algorithm », *IEEE Trans. Image Process.*, vol. 19, n° 5, p. 1328-1337, mai 2010, [doi: 10.1109/TIP.2010.2040763](https://doi.org/10.1109/TIP.2010.2040763).
- [122] M. Gong, Y. Liang, J. Shi, W. Ma, et J. Ma, « Fuzzy C-Means Clustering With Local Information and Kernel Metric for Image Segmentation », *IEEE Trans. Image Process.*, vol. 22, n° 2, p. 573-584, févr. 2013, [doi: 10.1109/TIP.2012.2219547](https://doi.org/10.1109/TIP.2012.2219547).
- [123] A. Elazab, C. Wang, F. Jia, J. Wu, P. Li, et Q. Hu, « Segmentation of Brain Tissues from Magnetic Resonance Images Using Adaptively Regularized Kernel-Based Fuzzy C -Means Clustering », *Comput. Math. Methods Med.*, vol. 2015, p. 1-12, janv. 2015, [doi: 10.1155/2015/485495](https://doi.org/10.1155/2015/485495).
- [124] F. Zhao, L. Jiao, et H. Liu, « Kernel generalized fuzzy c-means clustering with spatial information for image segmentation », *Digit. Signal Process.*, vol. 23, n° 1, p. 184-199, janv. 2013, [doi: 10.1016/j.dsp.2012.09.016](https://doi.org/10.1016/j.dsp.2012.09.016).
- [125] X.-X. Wang, J. Shen, et F. Guo, « Adaptive fuzzy c-means algorithm based on local noise detecting for image segmentation », *IET Image Process.*, vol. 10, janv. 2016, [doi: 10.1049/iet-ipr.2015.0236](https://doi.org/10.1049/iet-ipr.2015.0236).
- [126] Z. Zaixin, C. Lizhi, et C. Guangquan, « Neighborhood weighted fuzzy c-means clustering algorithm for image segmentation », *Image Process. IET*, vol. 8, p. 150-161, mars 2014, [doi: 10.1049/iet-ipr.2011.0128](https://doi.org/10.1049/iet-ipr.2011.0128).
- [127] T. Lei, X. Jia, Y. Zhang, L. He, H. Meng, et A. K. Nandi, « Significantly Fast and Robust Fuzzy C-Means Clustering Algorithm Based on Morphological Reconstruction and Membership Filtering », *IEEE Trans. Fuzzy Syst.*, vol. 26, n° 5, p. 3027-3041, oct. 2018, [doi: 10.1109/TFUZZ.2018.2796074](https://doi.org/10.1109/TFUZZ.2018.2796074).

- [128] J.-J. Chen, C.-R. Su, W. E. L. Grimson, J.-L. Liu, et D.-H. Shiue, « Object Segmentation of Database Images by Dual Multiscale Morphological Reconstructions and Retrieval Applications », *IEEE Trans. Image Process.*, vol. 21, n° 2, p. 828-843, févr. 2012, [doi: 10.1109/TIP.2011.2166558](https://doi.org/10.1109/TIP.2011.2166558).
- [129] M. Á. Carreira-Perpiñán et G. Hinton, « On Contrastive Divergence Learning », in *International Workshop on Artificial Intelligence and Statistics*, janv. 2005, p. 33-40. <https://proceedings.mlr.press/r5/carreira-perpinan05a.html>
- [130] Y. Bengio, « Learning Deep Architectures for AI », p. 56.
- [131] Y. Chen, H. Jiang, C. Li, X. Jia, et P. Ghamisi, « Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks », *IEEE Trans. Geosci. Remote Sens.*, vol. 54, n° 10, p. 6232-6251, oct. 2016, [doi: 10.1109/TGRS.2016.2584107](https://doi.org/10.1109/TGRS.2016.2584107).
- [132] S. Quan, B. Xiong, D. Xiang, L. Zhao, S. Zhang, et G. Kuang, « Eigenvalue-Based Urban Area Extraction Using Polarimetric SAR Data », *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 11, n° 2, p. 458-471, févr. 2018, [doi: 10.1109/JSTARS.2017.2787591](https://doi.org/10.1109/JSTARS.2017.2787591).
- [133] M. Volpi et M. Kanevski, « Supervised Change Detection in VHR Images Using Support Vector Machines and Contextual Information », mai 2010.
- [134] G. Sarp et M. Ozcelik, « Water body extraction and change detection using time series: A case study of Lake Burdur, Turkey », *J. Taibah Univ. Sci.*, vol. 11, n° 3, p. 381-391, mai 2017, [doi: 10.1016/j.jtusci.2016.04.005](https://doi.org/10.1016/j.jtusci.2016.04.005).
- [135] H. Kusatogullari, A. Yavariabdi, et T. Celik, « Unsupervised Change Detection in Multitemporal Multispectral Satellite Images Using Parallel Particle Swarm Optimization », *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 8, p. 1-14, mai 2015, [doi: 10.1109/JSTARS.2015.2427274](https://doi.org/10.1109/JSTARS.2015.2427274).
- [136] T. Celik, « Change Detection in Satellite Images Using a Genetic Algorithm Approach », *IEEE Geosci. Remote Sens. Lett.*, vol. 7, n° 2, p. 386-390, avr. 2010, [doi: 10.1109/LGRS.2009.2037024](https://doi.org/10.1109/LGRS.2009.2037024).
- [137] W. Ma, Y. Wu, M. Gong, Y. Xiong, H. Yang, et T. Hu, « Change detection in SAR images based on matrix factorisation and a Bayes classifier », *Int. J. Remote Sens.*, vol. 40, n° 3, p. 1066-1091, févr. 2019, [doi: 10.1080/01431161.2018.1524172](https://doi.org/10.1080/01431161.2018.1524172).
- [138] Y. Bazi, L. Bruzzone, et F. Melgani, « Image thresholding based on the EM algorithm and the generalized Gaussian distribution », *Pattern Recognit.*, vol. 40, n° 2, p. 619-634, févr. 2007, [doi: 10.1016/j.patcog.2006.05.006](https://doi.org/10.1016/j.patcog.2006.05.006).
- [139] L. Jia, M. Li, P. Zhang, Y. Wu, et H. Zhu, « SAR Image Change Detection Based on Multiple Kernel K-Means Clustering With Local-Neighborhood Information », *IEEE Geosci. Remote Sens. Lett.*, vol. 13, n° 6, p. 856-860, juin 2016, [doi: 10.1109/LGRS.2016.2550666](https://doi.org/10.1109/LGRS.2016.2550666).
- [140] H. Li, M. Gong, Q. Wang, J. Liu, et L. Su, « A multiobjective fuzzy clustering method for change detection in SAR images », *Appl. Soft Comput.*, vol. 46, p. 767-777, sept. 2016, [doi: 10.1016/j.asoc.2015.10.044](https://doi.org/10.1016/j.asoc.2015.10.044).
- [141] X.-D. Wang, R.-C. Chen, F. Yan, Z.-Q. Zeng, et C.-Q. Hong, « Fast Adaptive K-Means Subspace Clustering for High-Dimensional Data », *IEEE Access*, vol. 7, p. 42639-42651, 2019, [doi: 10.1109/ACCESS.2019.2907043](https://doi.org/10.1109/ACCESS.2019.2907043).
- [142] A. Krizhevsky, I. Sutskever, et G. E. Hinton, « ImageNet classification with deep convolutional neural networks », *Commun. ACM*, vol. 60, n° 6, p. 84-90, mai 2017, [doi: 10.1145/3065386](https://doi.org/10.1145/3065386).
- [143] Q. Wang, X. Zhang, G. Chen, F. Dai, Y. Gong, et K. Zhu, « Change detection based on Faster R-CNN for high-resolution remote sensing images », *Remote Sens. Lett.*, vol. 9, n° 10, p. 923-932, oct. 2018, [doi: 10.1080/2150704X.2018.1492172](https://doi.org/10.1080/2150704X.2018.1492172).
- [144] F. Liu, L. Jiao, X. Tang, S. Yang, W. Ma, et B. Hou, « Local Restricted Convolutional Neural Network for Change Detection in Polarimetric SAR Images », *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 30, n° 3, p. 818-833, mars 2019, [doi: 10.1109/TNNLS.2018.2847309](https://doi.org/10.1109/TNNLS.2018.2847309).
- [145] H. Dong, W. Ma, Y. Wu, M. Gong, et L. Jiao, « Local Descriptor Learning for Change Detection in Synthetic Aperture Radar Images via Convolutional Neural Networks », *IEEE Access*, vol. PP, p. 1-1, déc. 2018, [doi: 10.1109/ACCESS.2018.2889326](https://doi.org/10.1109/ACCESS.2018.2889326).
- [146] G. E. Hinton, A. Krizhevsky, et S. D. Wang, « Transforming Auto-Encoders », in *Artificial Neural Networks and Machine Learning – ICANN 2011*, vol. 6791, T. Honkela, W. Duch, M. Girolami, et

- S. Kaski, Éd. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011, p. 44-51. [doi: 10.1007/978-3-642-21735-7_6](https://doi.org/10.1007/978-3-642-21735-7_6).
- [147] S. Sabour, N. Frosst, et G. E. Hinton, « Dynamic Routing Between Capsules », p. 11.
- [148] I. O. Ertugrul, L. A. Jeni, et J. F. Cohn, « FACSCaps: Pose-Independent Facial Action Coding with Capsules », in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, juin 2018, p. 2211-221109. [doi: 10.1109/CVPRW.2018.00287](https://doi.org/10.1109/CVPRW.2018.00287).
- [149] K. Zhu, Y. Chen, P. Ghamisi, X. Jia, et J. A. Benediktsson, « Deep Convolutional Capsule Network for Hyperspectral Image Spectral and Spectral-Spatial Classification », *Remote Sens.*, vol. 11, n° 3, Art. n° 3, janv. 2019, [doi: 10.3390/rs11030223](https://doi.org/10.3390/rs11030223).
- [150] M. E. Paoletti et al., « Capsule Networks for Hyperspectral Image Classification », *IEEE Trans. Geosci. Remote Sens.*, vol. 57, n° 4, p. 2145-2160, avr. 2019, [doi: 10.1109/TGRS.2018.2871782](https://doi.org/10.1109/TGRS.2018.2871782).
- [151] Y. Gao, F. Gao, J. Dong, et H.-C. Li, « SAR Image Change Detection Based on Multiscale Capsule Network », *IEEE Geosci. Remote Sens. Lett.*, vol. 18, n° 3, p. 484-488, mars 2021, [doi: 10.1109/LGRS.2020.2977838](https://doi.org/10.1109/LGRS.2020.2977838).
- [152] Y. Hou, T. Xu, H. Hu, P. Wang, H. Xue, et Y. Bai, « MdpCaps-Csl for SAR Image Target Recognition With Limited Labeled Training Data », *IEEE Access*, vol. 8, p. 176217-176231, 2020, [doi: 10.1109/ACCESS.2020.3026469](https://doi.org/10.1109/ACCESS.2020.3026469).
- [153] J. Hu, L. Shen, et G. Sun, « Squeeze-and-Excitation Networks », in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, juin 2018, p. 7132-7141. [doi: 10.1109/CVPR.2018.00745](https://doi.org/10.1109/CVPR.2018.00745).
- [154] Y. Zhang, Y. Tian, Y. Kong, B. Zhong, et Y. Fu, « Residual Dense Network for Image Super-Resolution ». arXiv, 26 mars 2018. [doi: 10.48550/arXiv.1802.08797](https://doi.org/10.48550/arXiv.1802.08797).
- [155] Yanminsun, A. Wong, et M. S. Kamel, « Classification of imbalanced data: a review », *Int. J. Pattern Recognit. Artif. Intell.*, vol. 23, nov. 2011, [doi: 10.1142/S0218001409007326](https://doi.org/10.1142/S0218001409007326).
- [156] M. Rocchetti, G. Delnevo, L. Casini, et S. Mirri, « An alternative approach to dimension reduction for pareto distributed data: a case study », *J. Big Data*, vol. 8, n° 1, p. 39, févr. 2021, [doi: 10.1186/s40537-021-00428-8](https://doi.org/10.1186/s40537-021-00428-8).
- [157] Q. Xu, K. Chen, X. Sun, Y. Zhang, H. Li, et G. Xu, « Pseudo-Siamese Capsule Network for Aerial Remote Sensing Images Change Detection », *IEEE Geosci. Remote Sens. Lett.*, vol. 19, p. 1-5, 2022, [doi: 10.1109/LGRS.2020.3022512](https://doi.org/10.1109/LGRS.2020.3022512).
- [158] F. Gao, J. Dong, B. Li, et Q. Xu, « Automatic Change Detection in Synthetic Aperture Radar Images Based on PCANet », *IEEE Geosci. Remote Sens. Lett.*, vol. 13, n° 12, p. 1792-1796, déc. 2016, [doi: 10.1109/LGRS.2016.2611001](https://doi.org/10.1109/LGRS.2016.2611001).
- [159] J. B. Campbell, R. H. Wynne, et V. A. Thomas, *Introduction to Remote Sensing*. Guilford Publications, 2022.
- [160] « Polarimetric Radar Imaging: From Basics to Applications - 1st Edition ». <https://www.routledge.com/Polarimetric-Radar-Imaging-From-Basics-to-Applications/Lee-Pottier/p/book/9781420054972>
- [161] F. T. Ulaby et C. Elachi, *Radar Polarimetry for Geoscience Applications*. Artech House, 1990.
- [162] N. E. C. Verhoest, H. Lievens, W. Wagner, J. Álvarez-Mozos, M. S. Moran, et F. Mattia, « On the Soil Roughness Parameterization Problem in Soil Moisture Retrieval of Bare Surfaces from Synthetic Aperture Radar », *Sensors*, vol. 8, n° 7, Art. n° 7, juill. 2008, [doi: 10.3390/s8074213](https://doi.org/10.3390/s8074213).
- [163] S. Gharechelou, R. Tateishi, R. C. Sharma, et B. A. Johnson, « Soil Moisture Mapping in an Arid Area Using a Land Unit Area (LUA) Sampling Approach and Geostatistical Interpolation Techniques », *ISPRS Int. J. Geo-Inf.*, vol. 5, n° 3, Art. n° 3, mars 2016, [doi: 10.3390/ijgi5030035](https://doi.org/10.3390/ijgi5030035).
- [164] G. Liu, L. Jiao, F. Liu, H. Zhong, et S. Wang, « A new patch based change detector for polarimetric SAR data », *Pattern Recognit.*, vol. 48, n° 3, p. 685-695, mars 2015, [doi: 10.1016/j.patcog.2014.09.027](https://doi.org/10.1016/j.patcog.2014.09.027).
- [165] M. Liu, H. Zhang, C. Wang, et F. Wu, « Change Detection of Multilook Polarimetric SAR Images Using Heterogeneous Clutter Models », *IEEE Trans. Geosci. Remote Sens.*, vol. 52, n° 12, p. 7483-7494, déc. 2014, [doi: 10.1109/TGRS.2014.2310451](https://doi.org/10.1109/TGRS.2014.2310451).

- [166] V. Akbari, S. N. Anfinsen, A. P. Doulgeris, T. Eltoft, G. Moser, et S. B. Serpico, « Polarimetric SAR Change Detection With the Complex Hotelling–Lawley Trace Statistic », *IEEE Trans. Geosci. Remote Sens.*, vol. 54, n° 7, p. 3953-3966, juill. 2016, doi: [10.1109/TGRS.2016.2532320](https://doi.org/10.1109/TGRS.2016.2532320).
- [167] S. Mahdavi, B. Salehi, W. Huang, M. Amani, et B. Brisco, « A PolSAR Change Detection Index Based on Neighborhood Information for Flood Mapping », *Remote Sens.*, vol. 11, n° 16, Art. n° 16, janv. 2019, doi: [10.3390/rs11161854](https://doi.org/10.3390/rs11161854).
- [168] K. Conradsen, A. Nielsen, J. Schou, et H. Skriver, « A test statistic in the complex Wishart distribution and its application to change detection in polarimetric SAR data », *Geosci. Remote Sens. IEEE Trans. On*, vol. 41, p. 4-19, févr. 2003, doi: [10.1109/TGRS.2002.808066](https://doi.org/10.1109/TGRS.2002.808066).
- [169] P. R. Kersten, J. S. Lee, et T. L. Ainsworth, « A comparison of change detection statistics in POLSAR images », in *Proceedings. 2005 IEEE International Geoscience and Remote Sensing Symposium, 2005. IGARSS '05.*, juill. 2005, vol. 7, p. 4836-4839. doi: [10.1109/IGARSS.2005.1526756](https://doi.org/10.1109/IGARSS.2005.1526756).
- [170] K. Conradsen, A. A. Nielsen, et H. Skriver, « Determining the Points of Change in Time Series of Polarimetric SAR Data », *IEEE Trans. Geosci. Remote Sens.*, vol. 54, n° 5, p. 3007-3024, mai 2016, doi: [10.1109/TGRS.2015.2510160](https://doi.org/10.1109/TGRS.2015.2510160).
- [171] K. D. Ward, « Compound representation of high resolution sea clutter », *Electron. Lett.*, vol. 17, n° 16, p. 561-563, août 1981, doi: [10.1049/el:19810394](https://doi.org/10.1049/el:19810394).
- [172] E. Erten, A. Reigber, L. Ferro-Famil, et O. Hellwich, « A New Coherent Similarity Measure for Temporal Multichannel Scene Characterization », *IEEE Trans. Geosci. Remote Sens.*, vol. 50, n° 7, p. 2839-2851, juill. 2012, doi: [10.1109/TGRS.2011.2174155](https://doi.org/10.1109/TGRS.2011.2174155).
- [173] G. Mercier, G. Moser, et S. B. Serpico, « Conditional Copulas for Change Detection in Heterogeneous Remote Sensing Images », *IEEE Trans. Geosci. Remote Sens.*, vol. 46, n° 5, p. 1428-1441, mai 2008, doi: [10.1109/TGRS.2008.916476](https://doi.org/10.1109/TGRS.2008.916476).
- [174] A. Nascimento, R. Cintra, et A. Frery, « Hypothesis Testing in Speckled Data With Stochastic Distances », *Geosci. Remote Sens. IEEE Trans. On*, vol. 48, févr. 2010, doi: [10.1109/TGRS.2009.2025498](https://doi.org/10.1109/TGRS.2009.2025498).
- [175] M. Ghanbari et V. Akbari, « Unsupervised Change Detection in Polarimetric SAR Data With the Hotelling–Lawley Trace Statistic and Minimum-Error Thresholding », *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 11, n° 12, p. 4551-4562, déc. 2018, doi: [10.1109/JSTARS.2018.2882412](https://doi.org/10.1109/JSTARS.2018.2882412).
- [176] S. T. Seydi, M. Hasanlou, et M. Amani, « A New End-to-End Multi-Dimensional CNN Framework for Land Cover/Land Use Change Detection in Multi-Source Remote Sensing Datasets », *Remote Sens.*, vol. 12, n° 12, Art. n° 12, janv. 2020, doi: [10.3390/rs12122010](https://doi.org/10.3390/rs12122010).
- [177] V. Ziegler, E. Luneburg, et A. Schroth, « Mean Backscattering Properties Of Random Radar Targets: A Polarimetric Covariance Matrix Concept », in *[Proceedings] IGARSS '92 International Geoscience and Remote Sensing Symposium*, mai 1992, vol. 1, p. 266-268. doi: [10.1109/IGARSS.1992.576686](https://doi.org/10.1109/IGARSS.1992.576686).
- [178] J. Inglada et G. Alain, « On the possibility of automatic multisensor image registration », *IEEE Trans. Geosci. Remote Sens.*, vol. 42, n° 10, p. 2104-2120, oct. 2004.
- [179] R. J. Dekker, « Speckle filtering in satellite SAR change detection imagery », *Int. J. Remote Sens.*, vol. 19, n° 6, p. 1133-1146, janv. 1998, doi: [10.1080/014311698215649](https://doi.org/10.1080/014311698215649).
- [180] A. S. Yommy, R. Liu, Wu, et Shuang, « SAR Image Despeckling Using Refined Lee Filter », in *2015 7th International Conference on Intelligent Human-Machine Systems and Cybernetics*, août 2015, vol. 2, p. 260-265. doi: [10.1109/IHMSC.2015.236](https://doi.org/10.1109/IHMSC.2015.236).
- [181] J. T. Barron, « A Generalization of Otsu's Method and Minimum Error Thresholding ». arXiv, 18 août 2020. doi: [10.48550/arXiv.2007.07350](https://doi.org/10.48550/arXiv.2007.07350).

Articles

- Attioui, S., Najah S. **Multidimensional parallel capsule network for SAR image change detection.** *Multimed Tools Appl.* (2022) <https://doi.org/10.1007/s11042-022-13622-4>.
- Attioui, S., Najah S. **Unsupervised change detection method in SAR images based on deep belief network using an improved fuzzy C-means clustering algorithm.** *IET Image Processing*, 2021, 15(4), pp. 974–982. <https://doi.org/10.1049/ipr2.12078>.

Conférences:

- Attioui, S., Najah S. **Water Feature Extraction and Change Detection Using SAR image** . Conference on Water, Agriculture, Environment and Energy Faculty of Sciences and Techniques, Fez – Morocco May 22 – 23, 2023
- Attioui, S., Najah S. **Deep Learning of Remote Sensing Data for analysing and detection urban sprawl.** Colloque internationale la Géomatique au Service de l'Aménagement du Territoire (GéoSAT) Enjeux de la Régionalisation avancée et du Nouveau Modèle de développement Tanger, les 02, 03 & 04 mai 2023
- Attioui, S., Najah S. **A Novel Deep Learning Framework for Polarimetry SAR Change Detection using Capsule Network.** *International Journal of Computer and Information Engineering* 16 (5), 196-200 (2022).
- Attioui, S., Najah, S. **A deep learning method for change detection in synthetic aperture radar images.** IMCIC 2021 - 12th International Multi-Conference on Complexity, Informatics, and Cybernetics, Proceedings, 2021, 1, pp. 25–29- Orlando, Florida,