

الجمهورية الجزائرية الديمقراطية الشعبية  
LA REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي  
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



Université Saad Dahlab Blida 1  
Institut d'Aéronautique et des Études Spatiales  
Département Études Spatiales



Mémoire de fin d'études  
En vue de l'obtention du diplôme de  
Master en Aéronautique  
Option : Télécommunications Spatiales

THEME

**Extraction des zones urbaines  
avec les images radar à synthèse d'ouverture (SAR)**

Proposé et dirigé par :

*Dr. AZMEDROUB Boussad*

*Dr. TAHRAOUI Sofiane*

Réalisé par :

*M. TRABELSI Islam Tarek*

*M. BERRABAH Mohamed Nadir*

*Soutenue le 09 juillet 2023, devant le jury composé de :*

*Dr. BENBLIDIA Nadjia*      *Président*

*Dr. AZMEDROUB Boussad*      *Encadreur*

*Dr. CHOUTRI Kheireddine*      *Examineur*

*Dr. TAHRAOUI Sofiane*      *Co-encadreur*

*Promotion : 2022 / 2023*



# Remerciement

Tout d'abord, nous tenons à exprimer nos sincères remerciements à Dieu Tout-Puissant pour nous avoir accordé la force et le courage nécessaires pour mener à bien ce travail.

Nous souhaitons exprimer notre gratitude particulière à Monsieur B. Azmedroub et Monsieur S. Tahraoui pour nous avoir proposé ce sujet de recherche et pour leur encadrement tout au long de notre parcours. Leurs connaissances, leur expérience et leurs conseils précieux ont été d'une grande aide pour la réalisation de ce mémoire.

Nous aimerions également exprimer notre profonde reconnaissance envers nos parents respectifs, qui nous ont soutenus et encouragés tout au long de cette aventure académique.

Nos remerciements vont également à tous les membres du jury qui ont accepté de consacrer leur temps pour évaluer notre travail et pour leurs précieuses observations et recommandations.

Enfin, nous tenons à exprimer notre gratitude envers tous nos enseignants qui ont contribué à notre formation et à notre développement académique.

Nous sommes conscients que sans le soutien et l'implication de toutes ces personnes, la réalisation de ce travail aurait été impossible. Nous leur sommes profondément reconnaissants pour leur précieuse contribution à notre réussite.

Que tous ceux qui ont contribué à notre parcours soient remerciés du fond du cœur.

## المخلص

يركز هذا البحث على استغلال صور SAR (Synthetic Aperture Radar) لاستخراج المناطق الحضرية. لقد استخدمنا صور SAR لسان فرانسيسكو وخليج الجزائر، الملتقطة على التوالي بواسطة أجهزة رادار Sentinel-1 و RADARSAT-2 من وكالة الفضاء الأوروبية ESA. قمنا بدراسة عدة طرق للكشف، سواء كانت طرق غير مراقبة أو مراقبة، مثل طريقة الترابط، وتحليلات ياماغوتشي وفريمان، بالإضافة إلى طرق التصنيفية OTSU و K-means، وطرق التصنيف SVM و MLP و Random Forest. باستخدام اختيار دقيق لمناطق الاهتمام (ROI) للتدريب، لاحظنا أن طريقة التصنيف SVM تعطي أفضل النتائج لاستخراج المناطق الحضرية. تفتح هذه النتائج أفقاً واعدة لرسم الخرائط الحضرية ومراقبتها باستخدام بيانات SAR، مع تطبيقات محتملة في التخطيط الحضري وإدارة الموارد.

## Résumé

Ce mémoire se concentre sur l'exploitation des images SAR pour l'extraction des zones urbaines. Nous avons utilisé des images SAR de San Francisco et de la baie d'Alger, acquises respectivement par les radars RADARSAT-2 et Sentinel-1 de l'ESA. Nous avons exploré plusieurs méthodes de détection, tant non supervisées que supervisées, telles que la méthode de cohérence, les décompositions de Yamaguchi et de Freeman, ainsi que les méthodes de seuillage OTSU et K-means, et les méthodes de classification SVM, MLP et Random Forest. En utilisant une sélection minutieuse des régions d'apprentissage (ROI), nous avons constaté que la méthode de classification SVM donnait les meilleurs résultats pour l'extraction des zones urbaines. Ces résultats ouvrent des perspectives prometteuses pour la cartographie et la surveillance des zones urbaines à partir de données SAR, avec des applications potentielles en planification urbaine et en gestion des ressources.

# Abstract

This thesis focuses on the exploitation of SAR images for urban area extraction. We utilized SAR images of San Francisco and the Bay of Algiers, acquired respectively by RADARSAT-2 and Sentinel-1 radars from ESA. We explored various detection methods, both unsupervised and supervised, including coherence-based methods, Yamaguchi and Freeman decompositions, OTSU and K-means thresholding methods, as well as SVM, MLP, and Random Forest classification methods. Through careful selection of training regions (ROI's), we found that SVM classification yielded the best results for urban area extraction. These findings present promising prospects for urban mapping and monitoring using SAR data, with potential applications in urban planning and resource management.

# Table des matières

Remerciement	i
Résumé	ii
Table des matières	iv
Listes des abréviations	vi
Table des figures	vii
Liste des tableaux	x
Introduction Générale	1
<b>1 Les images SAR</b>	<b>3</b>
1.1 Introduction . . . . .	3
1.2 Radar à synthèse d'ouverture (SAR) . . . . .	3
1.3 Principe de formation des images SAR . . . . .	4
1.4 Résolution des images SAR . . . . .	6
1.5 Equation radar . . . . .	7
1.6 La polarimétrie . . . . .	8
1.6.1 Les ondes électromagnétiques . . . . .	8
1.6.2 Types de polarisation . . . . .	9
1.6.2.1 Polarisation elliptique . . . . .	9
1.6.2.2 Polarisation circulaire . . . . .	10
1.6.2.3 Polarisation linéaire . . . . .	11
1.6.3 Vecteur de Jones . . . . .	12
1.6.4 La matrice de diffusion . . . . .	13
1.6.5 Vecteur cible . . . . .	14
1.6.6 La matrice de cohérence et de covariance . . . . .	16

---

1.7	Décompositions polarimétriques . . . . .	17
1.7.1	Décomposition de YAMAGUCHI . . . . .	18
1.7.1.1	Décomposition quadripolaire de la puissance de diffusion . . . . .	18
1.7.2	Décomposition de Freeman et Durden . . . . .	21
1.7.3	La différence entre les deux décompositions . . . . .	24
1.8	conclusion . . . . .	25
<b>2</b>	<b>Méthodes de classification</b>	<b>26</b>
2.1	Introduction . . . . .	26
2.2	Les méthodes de classification non-supervisées . . . . .	27
2.2.1	La méthode de seuillage . . . . .	27
2.2.1.1	La méthode de seuillage de K-means . . . . .	27
2.2.1.2	La méthode de seuillage d'OTSU . . . . .	30
2.3	Les méthodes de classification supervisées . . . . .	34
2.3.1	La méthode de classification SVM (Support Vector Machine) . . . . .	34
2.3.2	La méthode de classification MLP (Multi Layer Perceptron) . . . . .	39
2.3.3	La méthode de classification random forest . . . . .	46
2.4	Comparaison entre ces méthodes de classification . . . . .	50
2.5	Conclusion . . . . .	52
<b>3</b>	<b>Résultats et analyses</b>	<b>54</b>
3.1	Introduction . . . . .	54
3.2	Présentation des données . . . . .	54
3.3	Détection automatique des zones urbaines . . . . .	55
3.3.1	Décomposition polarimétrique d'images SAR . . . . .	56
3.3.2	Le seuillage d'Otsu et de k-means . . . . .	58
3.3.2.1	Le prétraitement des données . . . . .	59
3.4	Classification supervisée de la surface terrestre . . . . .	68
3.5	Conclusion . . . . .	73
	<b>Conclusion Générale</b>	<b>75</b>
	<b>Bibliographie</b>	<b>76</b>

# Listes des abréviations

CART	Classification And Regression Tree.
CHIRP	Compressed High Intensity Radar Pulse.
ESA	European Space Agency.
GRD	Ground Range Detected.
H	Horizontale
IA	Intelligence Artificielle (Artificial intelligence).
ID3	Iterative Dichotomiser.
IW	Interferometric Wide swath.
LHC	Polarisation circulaire gauche (Left Handed Circular).
MARS	Multivariate Adaptive Regression Splines.
MLP	Multi Layer Perceptron.
MSE	Mean Squared Error.
NASA	National Aeronautics and Space Administration.
OVA	One-Vs-All.
OVO	One-Vs-One.
PRF	La fréquence de répétition des impulsions (Pulse Repetition Frequency).
RADAR	Détection et Télémétrie par Onde Radio (Ratio Detection And Ranging).
RBF	Radial Basis Function.
ReLU	Rectified Linear Unit.
RF	Random Forest.
RGB	Rouge, Vert, Bleu (Red Green Blue).
RHC	Polarisation circulaire droite (Right Handed Circular).
RMSProp	Root Mean Square Propagation.
ROI	Region Of interest.
SAR	Radar à Synthèse d'ouverture (Synthetic Aperture Radar).
SGD	Stochastic Gradient Descent.
SLAR	Side Looking Airborne Radars.
SNAP	Sentinel Application Platform.
SVM	Support Vector Machine.
V	Vertical



# Table des figures

1.1	Première image SAR [1] . . . . .	4
1.2	Illustration de la géométrie de l'imagerie SAR [2] . . . . .	6
1.3	Principe de la compression d'impulsion [3] . . . . .	7
1.4	Deux ondes orthogonales propagent dans la direction de z [4] . . . . .	9
1.5	Ellipse de polarisation [4] . . . . .	11
1.6	Propagation d'une onde circulaire [4] . . . . .	11
1.7	Polarisation horizontale (a) Polarisation verticale (b) [4] . . . . .	12
1.8	Des images SAR avec des polarisations VV et VH . . . . .	13
1.9	La décomposition en quatre composantes des puissances de diffusion Ps, Pd, Pv et Pc. [5] . . . . .	21
1.10	(a) Diffusion de surface (b) Diffusion de double rebond (c) Diffusion de volume . . . . .	22
2.1	Tirage aléatoire des centres $C_1^0$ et $C_2^0$ . . . . .	28
2.2	Constitution des classes $I_1^0$ et $I_2^0$ . . . . .	28
2.3	Nouveaux centres $C_1^1$ et $C_2^1$ et nouvelles classes $I_1^1$ et $I_2^1$ (2ème itération) . . . . .	29
2.4	Nouveaux centres $C_1^2$ et $C_2^2$ et nouvelles classes $I_1^2$ et $I_2^2$ (3ème itération) . . . . .	29
2.5	Exemple des pixels d'une image et son niveau de Gray correspondant . . . . .	31
2.6	La déviation en deux classes en utilisant le seuil d'Otsu . . . . .	31
2.7	Tableau des calculs des variances . . . . .	33
2.8	Résultat final de l'image après le seuillage d'Otsu . . . . .	33
2.9	deux classes linéairement séparables . . . . .	35
2.10	Processus de maximisation de la marge [6] . . . . .	36
2.11	Deux classes non linéairement séparables . . . . .	37
2.12	Projection non linéaire des points. En bleu, la fonction de décision linéaire en 3D . . . . .	37
2.13	La fonction sigmoïde . . . . .	38
2.14	La fonction de décision non linéaire . . . . .	38

---

2.15 Méthodes OVA et OVO . . . . .	39
2.16 Relation entre le MLP et le IA [7] . . . . .	39
2.17 Diagramme du Perceptron Multi-Couches (MLP) avec quatre couches cachées.	40
2.18 Forward propagation . . . . .	42
2.19 Fonction sigmoïde . . . . .	42
2.20 La fonction tanh . . . . .	42
2.21 La fonction RELU . . . . .	43
2.22 Rétropropagation (backpropagation) . . . . .	45
2.23 Descente de gradient . . . . .	45
2.24 Arbre de décision . . . . .	47
2.25 L'entropie . . . . .	48
2.26 Gain d'information . . . . .	49
2.27 (a) une seule arbre de décision (b) 25 arbres de décision (c) 50 arbres de décision . . . . .	50
3.1 La région d'étude de San Francisco . . . . .	55
3.2 Baie d'Alger . . . . .	55
3.3 Vérité terrain (ROI) de la région de SAN FRANCISCO . . . . .	56
3.4 Résultat final . . . . .	57
3.5 couleurs RGB . . . . .	57
3.6 Résultat final après la condition . . . . .	58
3.7 Plateforme d'accès libre Copernicus Open Access Hub . . . . .	60
3.8 Le choix de la région . . . . .	60
3.9 Recherche avancée . . . . .	61
3.10 Les résultats obtenus . . . . .	61
3.11 Deux images avec deux dates différentes . . . . .	62
3.12 Le prétraitement des données SAR avec SNAP . . . . .	62
3.13 Etapes de traitement . . . . .	63
3.14 La correction de terrain de la deuxième image . . . . .	63
3.15 Organigramme des étapes de calcul des paramètres de la cohérence . . . . .	64
3.16 Étapes de calcul des paramètres de la cohérence . . . . .	64
3.17 les différentes caractéristiques des images dans un seul composite RGB . . . . .	65
3.18 Histogramme de la cohérence et de Mean db . . . . .	65
3.19 L'urbain footprint de l'image . . . . .	66
3.20 Superposition des deux image urban footprint et composite RGB . . . . .	67
3.21 Application de k-means sur l'image SAR . . . . .	67

---

3.22	Region Of Interest de San Francisco . . . . .	68
3.23	Classification "San Francisco" . . . . .	69
3.24	Matrices de confusion "San Francisco" . . . . .	69
3.25	Histogramme 3D représente la précision globale de chaque type de classification . . . . .	70
3.26	Histogramme groupé représente la précision globale de chaque type de classification . . . . .	70
3.27	Region Of Interest de San Francisco . . . . .	71
3.28	Classification "Baie d'Alger" . . . . .	71
3.29	Matrice de confusion "Baie d'Alger" . . . . .	72

# Liste des tableaux

1.1	Table des bandes de fréquences radar . . . . .	4
1.2	Table de la polarisation linéaire . . . . .	13
1.3	Les formes géométrique des cibles canoniques et leurs matrice de diffusion [4] . . . . .	15
3.1	Tableau des caractéristiques des images . . . . .	55
3.2	Les trois classes et leurs couleurs et leurs pixels . . . . .	56
3.3	La précision globale des classifieurs par rapport au classes . . . . .	69
3.4	La précision globale des classifieurs par rapport au classes . . . . .	70
3.5	Les trois classes et leurs couleurs et leurs pixels . . . . .	71
3.6	La précision globale . . . . .	72
3.7	La précision Kappa de San Francisco et de la baie d'Alger . . . . .	72

# Introduction Générale

L' extraction des zones urbaines à partir d'images SAR (Synthetic Aperture Radar) constitue un domaine de recherche en plein essor dans le domaine de la télédétection et de l'analyse d'images. Les images SAR offrent des avantages uniques, tels que la capacité à acquérir des données indépendamment des conditions météorologiques et d'illumination, ce qui en fait une source d'information précieuse pour l'étude des zones urbaines.

La problématique de ce mémoire vise à identifier les meilleures approches pour une extraction précise des zones urbaines à partir d'images SAR, tout en surmontant les défis spécifiques liés aux données SAR. Nous chercherons également à évaluer la pertinence de ces méthodes pour la cartographie urbaine et la surveillance des zones urbaines, avec un objectif d'amélioration de l'efficacité et de la fiabilité de l'extraction des zones urbaines à partir de données SAR.

Le présent mémoire se concentre sur l'extraction des zones urbaines à partir d'images SAR en utilisant différentes techniques et méthodes d'analyse. Nous avons structuré notre étude en trois chapitres distincts, chacun abordant des aspects spécifiques de cette problématique.

Le premier chapitre est dédié à l'exploration des images SAR et à leur compréhension en tant que source de données pour l'extraction des zones urbaines. Nous examinons les principes de base de la formation d'images SAR, les caractéristiques spécifiques des images SAR urbaines, ainsi que les défis et les opportunités qu'elles présentent. En outre, nous abordons l'importance de la polarimétrie dans l'interprétation des images SAR urbaines, ainsi que les décompositions planimétriques, notamment les méthodes de Yamaguchi et de Freeman, qui permettent d'extraire des informations polarimétriques précieuses pour la caractérisation des zones urbaines.

Le deuxième chapitre met l'accent sur les méthodes de classification supervisées et non supervisées utilisées dans l'extraction des zones urbaines à partir d'images SAR. Nous explorons en détail des approches supervisées telles que le SVM (Support Vector Machine), le MLP (Multilayer Perceptron) et le Random Forest, qui utilisent des ensembles d'apprentissage étiquetés pour classifier les zones urbaines. Nous étudions également des

---

méthodes de seuillage non supervisées, notamment les méthodes d'OTSU et de K-means, qui permettent de segmenter les images SAR urbaines en utilisant des critères statistiques. Chacune de ces méthodes est analysée en termes d'applicabilité, de précision et de limitations.

Le troisième et dernier chapitre de notre mémoire est consacré aux résultats et aux analyses obtenus à partir de l'application des méthodes de classification mentionnées précédemment. Nous commençons par présenter les données que nous avons utilisées, notamment une image de San Francisco et une image de la baie d'Alger, qui servent de cas d'étude pour évaluer la performance des méthodes de classification. Nous décrivons ensuite les procédures d'application des méthodes, les paramètres utilisés et les critères d'évaluation. Les résultats sont analysés et discutés en termes de précision de classification, de cohérence avec les zones urbaines réelles et de pertinence pour la cartographie urbaine.

# Chapitre 1

## Les images SAR

### 1.1 Introduction

Un radar est un système électronique utilisé pour détecter, localiser et suivre des objets à distance en utilisant des ondes radio ou micro-ondes. Le terme « radar » est en réalité une abréviation de l'expression anglaise « Radio Detection And Ranging » (en français « Détection et Télémétrie par ondes radio »). Le fonctionnement d'un radar est basé sur le principe de l'émission d'un signal électromagnétique généralement sous la forme d'ondes radio ou micro-ondes (il peut être appelé un signal blanc), qui se propage dans l'espace et est réfléchi par les objets rencontrés sur son chemin, ensuite il mesure le temps écoulé entre l'émission et la réception du signal après la réflexion, en utilisant cette information il peut déterminer non seulement la distance de l'objet ciblé mais aussi sa vitesse, sa direction de déplacement et parfois sa taille ou sa forme. Les radars sont utilisés dans plusieurs domaines vu leurs importances tels que le domaine de la navigation aérienne, maritime et terrestre, la météorologie, les applications militaires, la surveillance du trafic, la détection des obstacle ... etc.

### 1.2 Radar à synthèse d'ouverture (SAR)

Le radar à synthèse d'ouverture (en anglais « Synthetic Aperture Radar ») est une technologie radar capable de générer des images de régions ou d'objet quel que soit l'heure de la journée ou les conditions météorologiques [8]. Il est généralement monté sur des plateformes mobiles (avions, drones, navettes spatiales ou satellites), Le déploiement le plus courant de SAR est généralement dans les satellites et disponible par l'intermédiaire d'agences publiques telles que l'ESA avec Sentinel-1 et RADARSAT-2 et la NASA avec NISAR. Le radar à synthèse d'ouverture est un système radar actif fonctionnant dans la

P	0.025-0.390 GHz	133-76.9 cm
L	0.39-1.55 GHz	76.9-19.3 cm
S	1.55-4.20 GHz	19.3-7.1 cm
C	4.20-5.75 GHz	7.1-5.2 cm
X	5.75-1.90GHz	5.2-2.7 cm
Ku	1.9-22.0GHz	2.7-1.36 cm
Ka	22.0-36.0 GHz	1.36-0.83 cm

TABLE 1.1 – Table des bandes de fréquences radar

région du spectre des micro-ondes, généralement entre la bande P et la bande Ka comme présenté dans la table ci-dessous, et opère selon une géométrie latérale avec un éclairage perpendiculaire à la direction de la ligne de vol, contrairement aux radars conventionnels qui utilise une antenne fixe. Le SAR utilise le traitement du signal pour synthétiser une image 2D à haute résolution spatiale de la réflectivité de la surface terrestre à partir de tous les signaux reçus.

Les premiers systèmes SAR ont vu le jour au début des années 1950 et les premières images ont été acquises à la fin des années 1950. La figure 1.1 présente la première image SAR obtenue par l'Université du Michigan en 1957 à l'aide de lampes au mercure. C'est seulement avec l'arrivée du laser et les progrès en informatique et en électronique que la qualité de l'image s'est améliorée. Depuis le lancement de SEASAR, le premier SAR numérique sur satellite en 1978, les systèmes SAR ont fourni beaucoup d'informations pour l'étude de la Terre.




FIGURE 1.1 – Première image SAR [1]

### 1.3 Principe de formation des images SAR

Le principe de formation d'une image SAR (Synthetic Aperture Radar) repose sur l'utilisation d'un radar à antenne synthétique pour acquérir des données sur une zone spécifique. Contrairement aux radars conventionnels, qui utilisent une antenne fixe, le SAR utilise



une antenne qui se déplace par rapport à la scène observée. Voici les étapes principales du processus de formation des images SAR :

1. **Émission du signal** : Le SAR émet un signal radar sous forme d'impulsions électromagnétiques, généralement des ondes radio ou micro-ondes, en direction de la scène à observer. Les impulsions sont répétées selon une fréquence de répétition des impulsions (PRF) synchronisée avec la vitesse de déplacement de l'antenne.
2. **Réception du signal réfléchi** : L'antenne du SAR capte le signal réfléchi par les objets présents dans la scène. Le signal réfléchi contient des informations sur la distance, l'amplitude et la phase de l'onde réfléchie par chaque point de la scène.
3. **Échantillonnage et enregistrement des données** : Les données captées par l'antenne du SAR sont échantillonnées et enregistrées pour chaque point dans le temps. Ces données brutes constituent les échos radar reçus par l'antenne à différents instants. Le PRF détermine la fréquence à laquelle les impulsions sont répétées et, par conséquent, la densité d'échantillonnage temporelle.
4. **Compression du signal** : Les données échantillonnées sont généralement compressées pour réduire la quantité d'informations à traiter et à stocker. Cela est souvent réalisé en utilisant des techniques de compression basées sur les caractéristiques du signal radar.
5. **Correction des effets atmosphériques et topographiques** : Les données enregistrées peuvent subir des distorsions en raison des effets atmosphériques et topographiques. Des corrections sont appliquées pour compenser ces distorsions et obtenir une image plus précise.
6. **Traitement de l'antenne synthétique** : Le principe fondamental du SAR est de simuler une antenne virtuelle plus grande en combinant les échos reçus sur une longue distance. Cela permet d'améliorer la résolution spatiale de l'image. Les données échantillonnées à différents instants sont traitées et combinées pour former une antenne virtuelle.
7. **Traitement de l'image** : Les données traitées sont ensuite transformées en une image SAR. Des algorithmes spécifiques, tels que la transformation de Fourier et le filtrage, sont utilisés pour convertir les données brutes en une image interprétable.

Le résultat final est une image SAR qui présente une résolution spatiale élevée et qui peut fournir des informations détaillées sur la structure, la topographie et les caractéristiques des objets présents dans la scène observée. Les images SAR sont utilisées dans de nombreux domaines, tels que la cartographie, la surveillance environnementale, l'observation des ressources naturelles et la gestion des catastrophes.




FIGURE 1.2 – Illustration de la géométrie de l'imagerie SAR [2]

## 1.4 Résolution des images SAR

La résolution spatiale joue un rôle essentiel dans les systèmes imageurs, car elle permet de déterminer la capacité à distinguer des objets proches les uns des autres. Une résolution spatiale élevée signifie que deux objets voisins seront séparés et identifiables dans des cellules de résolution distinctes, tandis qu'une résolution plus faible entraînera leur regroupement dans la même cellule. Il existe deux types de résolution : la résolution radiale, et la résolution azimutale, qui concerne la séparation des objets dans le plan perpendiculaire à l'axe de l'antenne.

- **Résolution radiale :**

La résolution radiale concerne la séparation des objets le long de l'axe de l'antenne. La distance radiale au sol  $R_d$  dépend de l'angle d'incidence  $\theta$  et de la durée des impulsions émise par le radar  $\tau$ , donc sa formule est donnée par  $R_d = \frac{c \tau}{2 \sin \theta}$ . Il est essentiel d'utiliser des systèmes qui émettent par le côté SLAR (side looking airborne radars), car on n'aura pas une résolution spatiale si  $\theta = 0$ . On utilise le signal CHIRP (compressed high intensity radar pulse) pour augmenter la résolution [9], dont la formule est :

$$c(t) = p(t) \cos(w_0 + 0.5\alpha t)t = p(t) \cos(w_0 t + 0.5\alpha t^2) = p(t) \cos(2\pi f_0 t + 0.5\alpha t^2) \quad (1.1)$$

La compression d'impulsion est réalisée en calculant la corrélation entre le signal émis et le signal reçu comme illustré dans la figure 1.3.

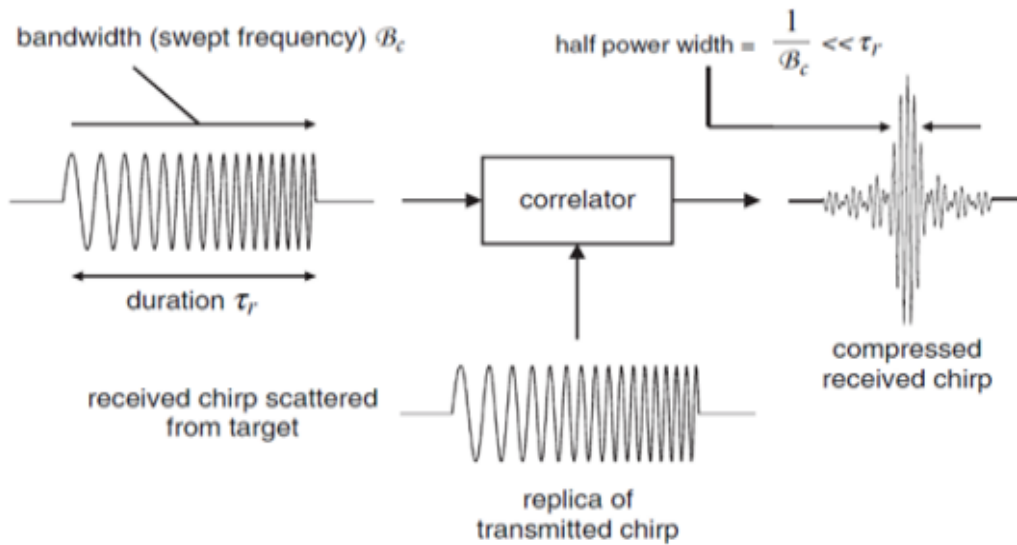


FIGURE 1.3 – Principe de la compression d'impulsion [3]

- **Résolution azimutale :**

La résolution azimutale est essentiellement la moitié de la longueur réelle de l'antenne utilisée et est exprimée par la formule :  $Ra = \frac{L}{2}$ , où "L" représente la longueur de l'antenne.

Pour améliorer la résolution en azimut, la méthode la plus efficace consisterait à augmenter la taille de l'antenne. Cependant, une taille d'antenne suffisamment grande pour obtenir une résolution élevée serait souvent impraticable. C'est là qu'intervient le principe du système SAR : la synthèse d'ouverture. En intégrant les signaux rétrodiffusés pour chaque point le long de la trajectoire du système radar, on parvient à créer une antenne synthétique virtuelle dont la taille est considérablement supérieure à celle de l'antenne réelle.

Une image SAR, tout comme tout autre type d'image, est composée d'une collection de pixels adjacents les uns aux autres. La valeur de ces pixels est déterminée par l'intensité du signal reçu et émis en direction de la surface (rétrodiffusion radar).

## 1.5 Equation radar

L'équation radar est une expression qui représente le bilan des puissances sur le trajet aller-retour d'une onde émise par un radar. Cette équation prend en compte les différents composants du radar tels que l'antenne, les circuits électroniques, le guide d'onde, les pertes de signal, ainsi que les caractéristiques et propriétés du milieu dans lequel l'onde se propage. Alors que les composants du radar sont généralement constants, les propriétés

du milieu et des cibles peuvent varier dans le temps et dans l'espace. L'équation radar permet de calculer la puissance moyenne rétrodiffusée en tout point de l'image. Elle est donnée par :

$$P_r = \frac{P_t G_t(\theta, \phi)}{4\pi r_t^2} \quad (1.2)$$

## 1.6 La polarimétrie

La polarimétrie est le domaine d'étude qui se concentre sur la polarisation des ondes électromagnétiques. Cette partie vise à présenter les concepts clés utilisés dans les radars SAR polarimétriques. Tout d'abord, nous rappellerons les mécanismes de propagation des ondes électromagnétiques. Ensuite, nous citons les formes de polarisation puis nous introduirons la notion de matrice de diffusion. Enfin, nous présenterons la matrice de cohérence et de covariance polarimétrique.

### 1.6.1 Les ondes électromagnétiques

L'interaction entre les ondes électromagnétiques et un milieu est essentielle pour déterminer les propriétés géophysiques de ce milieu. Les lois fondamentales de l'électromagnétisme, telles que la propagation des ondes et leur interaction avec la matière, sont décrites par les équations de Maxwell. Ces équations gouvernent tous les aspects de l'électromagnétisme.

Les équations de Maxwell expriment les relations fondamentales suivantes [4] :

$$\vec{\nabla} \times \vec{E} = -\frac{\partial \vec{B}}{\partial t} \quad (1.3)$$

$$\vec{\nabla} \times \vec{B} = \mu_0 \vec{J} + \mu_0 \varepsilon_0 \frac{\partial \vec{E}}{\partial t} \quad (1.4)$$

$$\vec{\nabla} \cdot \vec{E} = \frac{\rho}{\varepsilon_0} \quad (1.5)$$

$$\vec{\nabla} \cdot \vec{B} = 0 \quad (1.6)$$

$\varepsilon_0$  : permittivité de vide.

$\mu_0$  : perméabilité magnétique dans le vide.

$\rho$  : densité de charge.

$J$  : densité de courant des particules libres.

Dans le cas d'absence de charge  $\rho = 0$ ,  $J = 0$  et pour un milieu homogène, on peut obtenir une seule équation en combinant ces équations qui décrit la propagation du champ

électrique, formulée de la manière suivante :

$$\nabla^2 \vec{E} + \frac{1}{c^2} \frac{\partial^2 \vec{E}}{\partial t^2} \quad (1.7)$$

La solution de cette équation correspond à une onde plane monochromatique  $E$  se propageant le long de l'axe  $z$  d'un système tridimensionnel de coordonnées orthonormées. Ce système comporte deux composantes qui varient le long des axes  $h$  (horizontal) et  $v$  (vertical), et sont représentées par :

$$E_v(z, t) = E_{0,v} \cos(\pi + \delta_v) \quad (1.8)$$

$$E_h(z, t) = E_{0,h} \cos(\pi + \delta_h) \quad (1.9)$$

Avec :  $t = kz - wt$  et  $w = ck$ , où  $k$  représente le nombre d'onde et  $w$  la fréquence angulaire,  $\delta_v$  et  $\delta_h$  sont les phases absolues des deux composantes.




FIGURE 1.4 – Deux ondes orthogonales propagent dans la direction de  $z$  [4]

## 1.6.2 Types de polarisation

### 1.6.2.1 Polarisation elliptique

La polarisation elliptique est une forme de polarisation dans laquelle le vecteur du champ électrique décrit une trajectoire elliptique en se propageant dans l'espace. Cela signifie que l'orientation et l'amplitude du champ électrique varient de manière elliptique au cours du temps. La polarisation elliptique peut être obtenue en combinant des composantes de polarisation linéaire et circulaire avec des phases et des amplitudes appropriées.

Lorsque  $\delta_v$  est différent de  $\delta_h$  et que  $\delta = \delta_v - \delta_h$  (où  $\delta$  est la phase absolue), nous obtenons

l'équation suivante :

$$\frac{E_v}{E_{0v}} = \cos(\tau + \delta + \delta_h) = \cos(\tau + \delta_h) \cos \delta - \sin(\tau + \delta_h) \sin \delta \quad (1.10)$$

$$= \cos(\tau + \delta_h) \cos \delta - \sqrt{1 - \cos^2(\tau + \delta_h)} \sin \delta \quad (1.11)$$

$$= \frac{E_h}{E_{0h}} \cos \delta - \sqrt{1 - \frac{E_h^2}{E_{0h}^2}} \sin \delta \rightarrow \left( \frac{E_v}{E_{0v}} \right)^2 + \left( \frac{E_h}{E_{0h}} \right)^2 - \left( \frac{2E_v E_h}{E_{0v} E_{0h}} \right) \cos \delta = \sin^2 \delta \quad (1.12)$$

Dans cette équation,  $\frac{E_v}{E_{0v}}$  représente le rapport entre la composante verticale de l'amplitude du champ électrique  $E_v$  et son amplitude maximale  $E_{0v}$ .  $\tau$  est le déphasage initial,  $\cos(\tau + \delta_h)$  est le terme correspondant à la composante horizontale du champ électrique,  $\cos \delta$  est le terme cosinus de la différence de phase  $\delta$ , et  $\sin(\tau + \delta_h) \sin \delta$  est le terme sinus de la différence de phase  $\delta$ .

La dernière équation représente l'équation de l'ellipse de polarisation. Lorsque nous observons l'onde dans la direction de sa propagation, la pointe du vecteur du champ électrique d'une onde complètement polarisée trace une courbe qui prend la forme générale d'une ellipse dans un plan orthogonal à la direction de propagation.

Cependant, les paramètres  $E_{0v}$ ,  $E_{0h}$  et  $\delta$  des deux composantes du champ électrique ne sont pas pratiques pour décrire l'état de polarisation de l'onde. Il est plus commode d'utiliser deux angles définis à partir des paramètres géométriques de l'ellipse. L'ellipse possède un demi-grand axe  $\alpha_\xi$  et un demi-petit axe  $\alpha_\eta$ . L'angle du demi-grand axe, mesuré dans le sens antihoraire à partir de la moitié positive de l'axe horizontal, est appelé orientation  $\psi$  de l'onde électromagnétique. Sa valeur varie entre  $0^\circ$  et  $180^\circ$ .

L'aplatissement de l'ellipse est décrit par un autre paramètre appelé ellipticité, défini par l'équation :

$$\chi = \pm \arctan(\alpha_\eta/\alpha_\xi) \quad (1.13)$$

Où  $\alpha_\eta$  est le demi-petit axe de l'ellipse et  $\alpha_\xi$  est le demi-grand axe de l'ellipse. La valeur de  $\chi$  se situe entre  $-45^\circ$  et  $45^\circ$ . L'ouverture de l'ellipse ainsi que son signe indiquent la direction dans laquelle l'ellipse se déplace : une valeur de  $\chi$  positive indique une polarisation main gauche et une valeur de  $\chi$  négative une polarisation main-droite.

### 1.6.2.2 Polarisation circulaire

La polarisation circulaire est un type de polarisation où le vecteur du champ électrique de l'onde décrit un cercle lorsqu'on l'observe dans la direction de propagation. Il existe deux types de polarisation circulaire : la polarisation circulaire droite (RHC : Right Handed




FIGURE 1.5 – Ellipse de polarisation [4]

Circular) et la polarisation circulaire gauche (LHC : Left Handed Circular). Dans la polarisation circulaire droite ( $\chi = -45^\circ$ ), le champ électrique tourne dans le sens des aiguilles d'une montre, tandis que dans la polarisation circulaire gauche ( $\chi = +45^\circ$ ), le champ électrique tourne dans le sens inverse des aiguilles d'une montre. La polarisation circulaire peut être obtenue en combinant deux ondes orthogonales en phase et de même amplitude, déphasées de  $90^\circ$ .




FIGURE 1.6 – Propagation d'une onde circulaire [4]

### 1.6.2.3 Polarisation linéaire

La polarisation linéaire est la plus utilisée dans les systèmes radar, cette dernière est un type de polarisation où le vecteur du champ électrique de l'onde se déplace dans une direction spécifique, formant une ligne droite. Dans la polarisation linéaire, le champ électrique peut vibrer verticalement, horizontalement ou selon une direction inclinée. Il existe donc différents types de polarisation linéaire : la polarisation linéaire verticale, la polarisation linéaire horizontale et la polarisation linéaire inclinée.

Dans la polarisation linéaire verticale, le champ électrique oscille verticalement, c'est-à-dire perpendiculairement au sol. Dans la polarisation linéaire horizontale, le champ

électrique oscille horizontalement, parallèlement au sol. Dans la polarisation linéaire inclinée, le champ électrique oscille selon une direction inclinée par rapport à l'horizontale.

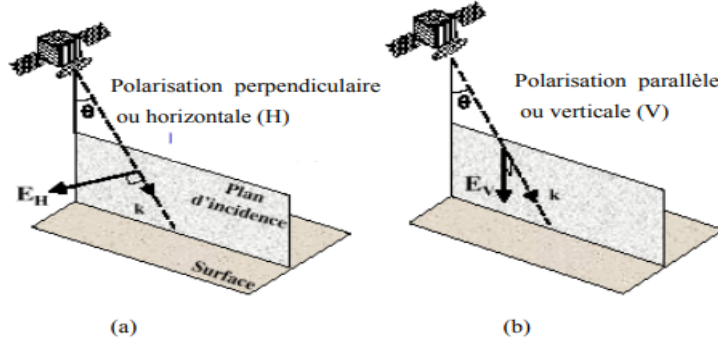


FIGURE 1.7 – Polarisation horizontale (a) Polarisation verticale (b) [4]

### 1.6.3 Vecteur de Jones

Le vecteur de Jones est utilisé pour représenter la polarisation d'une onde de manière concise. Le champ électrique peut ainsi être exprimé de la manière suivante [1] :

$$\vec{E}(z, t) = \begin{bmatrix} E_{0x} \cos(\omega t - kz + \delta_x) \\ E_{0y} \cos(\omega t - kz + \delta_y) \\ 0 \end{bmatrix} = \text{Re} \left( \begin{bmatrix} E_{0x} e^{j\delta_x} \\ E_{0y} e^{j\delta_y} \\ 0 \end{bmatrix} e^{-jkz} e^{j\omega t} \right) \quad (1.14)$$

$$= \text{Re} \left\{ \underline{\vec{E}}(z) e^{j\omega t} \right\} \quad (1.15)$$

Le vecteur de Jones  $\underline{E}$  est donc défini par :

$$\underline{E} = \vec{E}(z) \Big|_{(z=0)} = \begin{bmatrix} E_{0x} e^{j\delta_x} \\ E_{0y} e^{j\delta_y} \end{bmatrix} \quad (1.16)$$

Puisque le terme en  $z$  est nul, On peut également exprimer le champ électrique en fonction des caractéristiques de l'ellipse de polarisation :

$$\underline{E} = A e^{j\alpha} \begin{bmatrix} \cos(\phi) \cos(\tau) - j \sin(\phi) \sin(\tau) \\ \sin(\phi) \cos(\tau) - j \cos(\phi) \sin(\tau) \end{bmatrix} \quad (1.17)$$

$$= A e^{j\alpha} \begin{bmatrix} \cos(\phi) & -\sin(\phi) \\ \sin(\phi) & \cos(\phi) \end{bmatrix} \begin{bmatrix} \cos(\tau) \\ j \sin(\tau) \end{bmatrix} \quad (1.18)$$




### 1.6.4 La matrice de diffusion

Lorsque les ondes électromagnétiques se propagent et rencontrent un objet, elles interagissent avec celui-ci. Pendant cette interaction, l'objet peut absorber une partie de l'énergie de l'onde incidente, tandis que le reste est réfléchi ou diffusé. Ces interactions peuvent modifier les propriétés de polarisation de l'onde réfléchie par rapport à l'onde incidente. En mesurant ces changements, il devient possible de caractériser les propriétés de l'objet rencontré par l'onde incidente.


La polarimétrie SAR classique consiste à émettre deux polarisations orthogonales  $H$  et  $V$ , la réception est effectuée sur deux canaux après chaque émission.

Polarisation émise	Polarisation reçue	Composante mesurée
H	H	$S_{HH}$
	V	$S_{HV}$
V	H	$S_{VH}$
	V	$S_{VV}$

TABLE 1.2 – Table de la polarisation linéaire



(a) VV



(b) VH

FIGURE 1.8 – Des images SAR avec des polarisations VV et VH

La matrice de diffusion (scatring matrix) est une matrice de dimension  $(2 \times 2)$ , représentée par  $S = \begin{bmatrix} S_{11} & S_{12} \\ S_{21} & S_{22} \end{bmatrix}$  et ses éléments complexes  $S_{ij}$ , permet de caractériser l'interaction d'une onde électromagnétique avec un objet. Les coefficients co-polarisés (co-pol), présents sur la diagonale de la matrice, correspondent aux éléments  $S_{11}$  et  $S_{22}$ . Ces coefficients représentent la polarisation identique en émission et en réception. Les coefficients cross-polarisés (cross-pol), situés en dehors de la diagonale, comprennent les éléments  $S_{12}$  et  $S_{21}$ . Ils indiquent la polarisation croisée entre l'émission et la réception de l'onde.

Dans ce mémoire, la base de polarisation utilisée est la base de polarisation cartésienne horizontale verticale (H, V) puisque les images utilisées sont décrites dans cette base.

$$S = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \quad (1.19)$$

Dans la section précédente, nous avons introduit le vecteur de Jones comme un outil pour caractériser l'état de polarisation d'une onde. En utilisant le vecteur de Jones de l'onde incidente  $E_I$  et la matrice de diffusion, également connue sous le nom de matrice de Sinclair, il est possible d'établir une relation entre le vecteur de Jones de l'onde incidente et celui de l'onde réfléchie  $E_R$  en fonction de la matrice de diffusion  $[S]$  :

$$\underline{E}_R = \frac{e^{-jkr}}{r} S \underline{E}_I \quad (1.20)$$

Où :

–  $E_I$  : l'onde incidente, est donnée par :

$$\vec{E}^I = E_v^I \vec{V}_I + E_h^I \vec{H}_I \quad (1.21)$$

–  $E_R$  : l'onde réfléchie, est donnée par :

$$\vec{E}^R = E_v^R \vec{V}_I + E_h^R \vec{H}_R \quad (1.22)$$

–  $r$  : la distance entre le diffuseur et l'antenne.

–  $k$  : le nombre d'ondes

La matrice de diffusion contient toutes les propriétés polarimétriques d'une cible (d'un pixel).

Voici un tableau 1.3 présentant les matrices de diffusion de quelques cibles canoniques dans la base de polarisation (H, V). L'angle  $\varphi$  indique l'orientation de la cible canonique autour de l'axe de visée du radar et de l'axe de référence de symétrie principal :

### 1.6.5 Vecteur cible

Le vecteur cible est dérivé de la matrice de diffusion en remplaçant ses quatre éléments complexes, tout en préservant la signification de l'énergie totale. Ainsi, le vecteur cible est obtenu en exprimant les paramètres de polarisation de manière simplifiée, tels que l'intensité totale ou les différences entre les polarisations horizontale et verticale.

Le vecteur cible contient toute l'informations polarimétrique cohérente :

$$\vec{K} = \frac{1}{2} \text{trace}([S][\psi]) = [K_1, K_2, K_3, K_4]^T \quad (1.23)$$

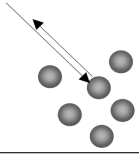
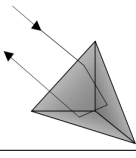
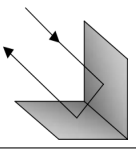
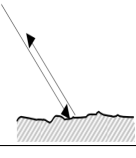
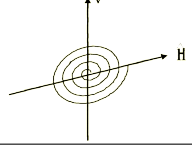
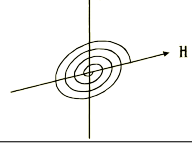
Cible	Matrice de diffusion	Forme géométrique
Sphère	$[S] = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$	
Trièdre	$[S] = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$	
Dièdre	$[S] = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$	
Surface	$[S] = \begin{bmatrix} a & 0 \\ 0 & b \end{bmatrix}$	
Hélice droite	$[S] = \frac{1}{2} \begin{bmatrix} 1 & -j \\ -j & -1 \end{bmatrix}$	
Hélice gauche	$[S] = \frac{1}{2} \begin{bmatrix} 1 & j \\ j & -1 \end{bmatrix}$	

TABLE 1.3 – Les formes géométrique des cibles canoniques et leurs matrice de diffusion [4]

Dans ce contexte, le terme  $[\psi]$  désigne un ensemble de matrices qui sont utilisées pour définir une base de projection.

Généralement, la base lexicographique  $[\psi_L]$  et la base de Pauli  $[\psi_P]$  sont les plus utilisées où :

La base lexicographique est définie par :

$$[\psi_L] = 2 \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}, \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}, \begin{bmatrix} 0 & 0 \\ 1 & 0 \end{bmatrix}, \begin{bmatrix} 0 & 0 \\ 0 & 1 \end{bmatrix} \quad (1.24)$$

Le vecteur cible correspondant est :

$$\vec{K}_L = [S_{hh}, S_{hv}, S_{vh}, S_{vv}] \quad (1.25)$$

La base de Pauli est définie par :

$$[\psi_P] = \sqrt{2} \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}, \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}, \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}, \begin{bmatrix} 0 & -i \\ i & 0 \end{bmatrix} \quad (1.26)$$

Le vecteur cible correspondant est :

$$\vec{K}_p = \frac{1}{\sqrt{2}} [(S_{hh} + S_{vv}), (S_{hh} - S_{vv}), (S_{hv} - S_{vh}), (S_{hv}S_{vh})]^T \quad (1.27)$$

Comme on a précisé précédemment  $S_{HV} = S_{VH}$ , donc le nombre d'éléments peut se réduire à 3, donc les vecteurs s'écrivent :

$$\vec{K}_p = [S_{hh}, \sqrt{2}S_{hv}, S_{vv}]^T \quad (1.28)$$

$$\vec{K}_L = [S_{hh} + S_{vv}, S_{hh} - S_{vv}, 2S_{hv}]^T \quad (1.29)$$

**Remarque :**

Les facteurs 2,  $\sqrt{2}$  sont nécessaires pour garder la norme des vecteurs indépendante du choix de la base de vectorisation.

### 1.6.6 La matrice de cohérence et de covariance

La matrice de cohérence  $[T_3]$  est utilisée pour évaluer la corrélation entre les différentes composantes du champ électrique sur une période de temps donnée "t". Contrairement à la matrice  $[S]$ , elle est générée en multipliant le vecteur cible de la base de Pauli par sa transposée conjuguée.

$$[T_3] = \langle \vec{K}_p \vec{K}_p^{*T} \rangle \quad (1.30)$$

$$[T_3] = \begin{bmatrix} \langle |S_{hh} + S_{vv}|^2 \rangle & \langle (S_{hh} + S_{vv})(S_{hh} + S_{vv})^* \rangle & 2\langle (S_{hh} + S_{vv})S_{hv}^* \rangle \\ \langle (S_{hh} - S_{vv})(S_{hh} + S_{vv})^* \rangle & \langle |S_{hh} - S_{vv}|^2 \rangle & 2\langle (S_{hh} - S_{vv})S_{hv}^* \rangle \\ 2\langle S_{hv}(S_{hh} + S_{vv})^* \rangle & 2\langle S_{hv}(S_{hh} + S_{vv})^* \rangle & 4\langle |S_{hv}|^2 \rangle \end{bmatrix} \quad (1.31)$$

La matrice de covariance est une mesure statistique utilisée pour quantifier la corrélation et la variance des variables aléatoires. On peut la générer par le produit du vecteur cible de la base lexicographique avec son conjugué transposé.

$$[C_3] = \langle \vec{K}_L \vec{K}_L^{*T} \rangle \quad (1.32)$$

$$[C_3] = \begin{bmatrix} \langle |S_{hh}|^2 \rangle & \sqrt{2}\langle S_{hh}S_{hv}^* \rangle & \langle S_{vv}S_{hh}^* \rangle \\ \sqrt{2}\langle S_{vh}S_{hh}^* \rangle & 2\langle |S_{hv}|^2 \rangle & \sqrt{2}\langle S_{hv}S_{vv}^* \rangle \\ \langle S_{vv}S_{hh}^* \rangle & \sqrt{2}\langle S_{vv}S_{hv}^* \rangle & \langle |S_{vv}|^2 \rangle \end{bmatrix} \quad (1.33)$$

En utilisant les deux matrices, il est possible d'atténuer le bruit présent dans les images polarimétriques en effectuant une moyenne sur un ensemble de cellules de résolution (pixels). Cela permet de réduire les variations aléatoires et d'améliorer la qualité générale des images en fournissant une estimation plus précise des caractéristiques polarimétriques des objets observés.

La conversion de la matrice de covariance à la matrice de cohérence ne conduit à aucune perte d'information, car les deux matrices contiennent exactement les mêmes informations.

## 1.7 Décompositions polarimétriques

Les modèles de décomposition sont utilisés pour exprimer la réponse polarimétrique d'une cible en une combinaison pondérée de rétrodiffusions provenant de cibles canoniques indépendantes. Ils permettent d'associer chaque composante générée à partir des données polarimétriques à un mécanisme physique de rétrodiffusion. On distingue deux types de modèles de décomposition dans la littérature : les décompositions cohérentes et les décompositions non-cohérentes.

- **Les décompositions cohérentes :**

Les décompositions cohérentes supposent qu'un pixel ne contient qu'un seul type de mécanisme de diffusion, et elles ne prennent pas en compte le voisinage. En d'autres termes, la réponse polarimétrique du pixel est principalement influencée par un seul type de cible ou de structure présente dans la scène observée. Ces modèles décomposent la matrice de diffusion en une somme de matrices de diffusion élémentaires  $[S] = \sum_{n=1}^k C_n[S_n]$ , chacune définissant un mécanisme de diffusion canonique. Les paramètres utilisés dans ces décompositions représentent les coefficients de rétrodiffusion des diffuseurs.

- **Les décompositions non-cohérentes :**

Les décompositions non-cohérentes supposent qu'un pixel peut contenir plusieurs types de diffusion. Pour réaliser leur analyse, elles prennent en compte le voisinage des pixels afin de tenir compte de la relation spatiale entre les pixels voisins. Ces décompositions décomposent les matrices de cohérence  $[T]$  ou de covariance en une somme de diffuseurs canoniques. Parmi les décompositions non-cohérentes les plus utilisées, on trouve la décomposition de Freeman et la décomposition de Yamaguchi. En général, les décompositions non-cohérentes donnent de meilleurs résultats par rapport aux décompositions cohérentes.

Pour la détection des zones urbaines, on utilise les décompositions de Yamaguchi et de Freeman, qui seront détaillées dans la section suivante. Elle permet de caractériser les propriétés de rétrodiffusion des structures urbaines en prenant en compte la relation spatiale entre les pixels voisins, ce qui permet une meilleure identification des zones urbaines dans les images SAR.

### 1.7.1 Décomposition de YAMAGUCHI

La décomposition de Yamaguchi est une méthode de décomposition non-cohérente utilisée pour analyser les données de polarimétrie à synthèse d'ouverture (SAR) en vue de détecter les caractéristiques spécifiques des zones urbaines. Cette décomposition permet de décomposer la matrice de cohérence  $[T]$  en quatre composantes, chacune représentant la puissance de rétrodiffusion d'un type de diffuseur canonique.

Les diffuseurs canoniques considérés dans la décomposition de Yamaguchi sont les suivants :

1. **Diffuseur volumique** : Cette composante représente la rétrodiffusion provenant des volumes, tels que les structures en trois dimensions présentes dans les zones urbaines, comme les bâtiments, les arbres ou les véhicules.
2. **Diffuseur surfacique** : Cette composante est associée à la rétrodiffusion provenant des surfaces planes, comme les toits des bâtiments, les routes ou les sols asphaltés. Elle permet de détecter les zones urbaines présentant des surfaces planes distinctes.
3. **Diffuseur double rebond** : Cette composante représente la rétrodiffusion résultant d'un double rebond entre des objets urbains, tels que les coins de bâtiments ou les intersections de routes. Elle permet de détecter des structures complexes et des configurations géométriques spécifiques des zones urbaines.
4. **Diffuseur en hélice** : Cette composante est associée à la rétrodiffusion provenant d'objets en rotation, tels que les pales de turbines éoliennes ou les hélicoptères. Elle permet de détecter des caractéristiques dynamiques des zones urbaines.

#### 1.7.1.1 Décomposition quadripolaire de la puissance de diffusion

Si l'on dispose d'un ensemble de données de matrice de diffusion pour la zone d'imagerie d'un pixel, on peut créer la matrice de cohérence correspondante, qui conserve les statistiques d'ordre deux de l'information polarimétrique. La moyenne de l'ensemble de la matrice de cohérence est donnée par [5] :

$$\langle [T] \rangle = \langle (k_p k_p^\dagger) \rangle \quad (1.34)$$

Où † représente la conjugaison complexe et la transposition,  $\langle \rangle$  désigne la moyenne de l'ensemble, et le vecteur de Pauli est défini comme suit :

$$k_p = \frac{1}{\sqrt{2}} \begin{bmatrix} S_{HH} + S_{VV} \\ S_{HH} - S_{VV} \\ 2S_{HV} \end{bmatrix} \quad (1.35)$$

Ensuite, la matrice de cohérence mesurée peut être décomposée en quatre sous-matrices correspondant aux mécanismes de diffusion en surface, en double rebond, en volume et en hélice.

$$\langle [T] \rangle = f_s \langle [T] \rangle_{surface} + f_d \langle [T] \rangle_{double} + f_v \langle [T] \rangle_{vol} + f_c \langle [T] \rangle_{helix} \quad (1.36)$$

Où  $f_s$ ,  $f_d$ ,  $f_v$  et  $f_c$  sont les coefficients d'expansion à déterminer. Ces quatre termes ont été dérivés à partir des modèles de diffusion physique, comme illustré dans la Figure 1.9 .

La matrice d'expansion pour la diffusion de surface est représentée par :

$$\langle [T] \rangle_{surface} = \begin{bmatrix} 1 & \beta^* & 0 \\ \beta & |\beta|^2 & 0 \\ 0 & 0 & 0 \end{bmatrix}, |\beta| < 1. \quad (1.37)$$

La matrice d'expansion pour la diffusion à double rebond est donnée par :

$$\langle [T] \rangle_{double} = \begin{bmatrix} |\alpha|^2 & \alpha & 0 \\ \alpha^* & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}, |\alpha| < 1. \quad (1.38)$$

Où  $\alpha$  et  $\beta$  sont des inconnues à déterminer.

Pour la diffusion volumique, nous utilisons l'une des matrices suivantes en fonction de l'équilibre des magnitudes entre  $\langle |S_{HH}|^2 \rangle$  et  $\langle |S_{VV}|^2 \rangle$ .

$$\langle [T] \rangle_{vol} = \frac{1}{30} \begin{bmatrix} 15 & 5 & 0 \\ 5 & 7 & 0 \\ 0 & 0 & 8 \end{bmatrix} \quad (1.39)$$

Pour :

$$10 \log \left( \frac{\langle |S_{VV}|^2 \rangle}{\langle |S_{HH}|^2 \rangle} \right) < -2dB; \quad (1.40)$$

$$\langle [T] \rangle_{vol} = \frac{1}{4} \begin{bmatrix} 2 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (1.41)$$

Pour :

$$\left| 10 \log \left( \frac{\langle |S_{VV}|^2 \rangle}{\langle |S_{HH}|^2 \rangle} \right) \right| < -2dB; \quad (1.42)$$

$$\langle [T] \rangle_{vol} = \frac{1}{30} \begin{bmatrix} 15 & -5 & 0 \\ -5 & 7 & 0 \\ 0 & 0 & 8 \end{bmatrix} \quad (1.43)$$

Pour :

$$10 \log \left( \frac{\langle |S_{VV}|^2 \rangle}{\langle |S_{HH}|^2 \rangle} \right) > -2dB; \quad (1.44)$$

La matrice d'expansion pour la diffusion en hélice, qui tient compte de la condition de non-symétrie de réflexion, est la suivante :

$$\langle [T] \rangle_{helix} = \frac{1}{2} \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & \pm j \\ 0 & \mp j & 1 \end{bmatrix} \quad (1.45)$$

Les puissances de diffusion correspondantes (surface, double rebond, volume, hélice) sont calculées directement à partir des coefficients d'expansion de ces matrices lorsqu'elles sont appliquées à la décomposition. Cette décomposition prend en compte un déséquilibre de puissance du canal co-polarisé.  $\langle |S_{HH}|^2 \rangle$  et  $\langle |S_{VV}|^2 \rangle$ .

Dans le cas de  $\left| 10 \log \left( \frac{\langle |S_{VV}|^2 \rangle}{\langle |S_{HH}|^2 \rangle} \right) \right| > -2dB$ , les expressions de puissance deviennent :

$$P_c = f_c = 2 |Im \langle S_{HV}^* (S_{HH} - S_{VV}) \rangle| \quad (1.46)$$

$$P_v = f_v = 4T_{33} - 2P_c = 8 \langle |S_{HV}|^2 \rangle - 2P_c \quad (1.47)$$

$$P_s = f_s (1 + |\beta|^2) \quad (1.48)$$

$$P_d = f_d (1 + |\alpha|^2) \quad (1.49)$$

Il convient de noter ici que la contribution  $P_v$  est principalement déterminée par la composante  $T_{33}$ , qui est essentiellement identique à la composante  $HV$  en polarisation croisée.

L'algorithme de décomposition de puissance de diffusion à quatre composants présente les avantages suivants :

- Mise en œuvre simple ;
- Le temps de calcul est relativement court car seules des opérations simples sont nécessaires ;
- Les puissances décomposées correspondent à des mécanismes de diffusion physique, c'est-à-dire la diffusion en surface  $P_s$ , la diffusion en double rebond  $P_d$ , la diffusion en volume  $P_v$ , la diffusion en hélice (polarisation circulaire)  $P_c$  ;



- Les images en couleur codées en sortie sont directement reconnaissables et faciles à comprendre.

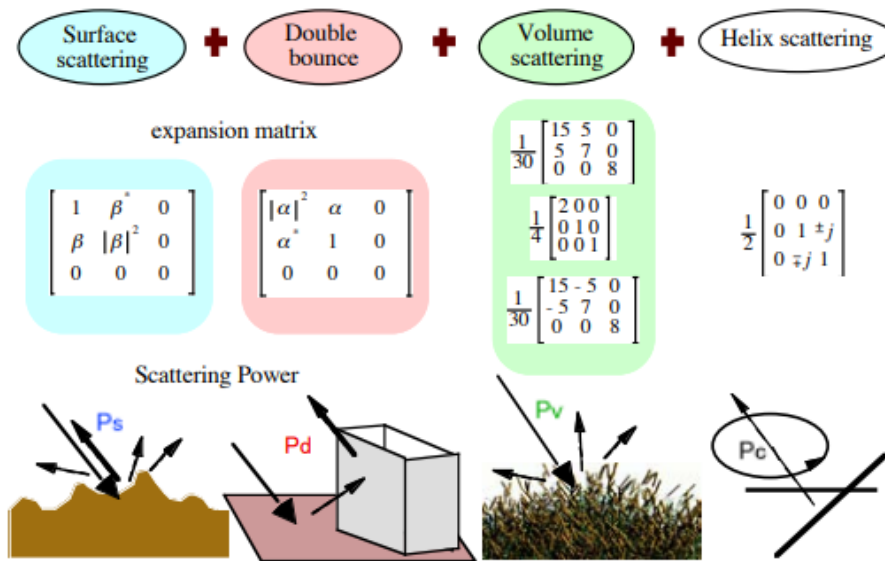


FIGURE 1.9 – La décomposition en quatre composantes des puissances de diffusion  $P_s$ ,  $P_d$ ,  $P_v$  et  $P_c$ . [5]

## 1.7.2 Décomposition de Freeman et Durden

La décomposition de Freeman et Durden est une technique de décomposition polarimétrique qui vise à caractériser la matrice de covariance  $[C]$  en termes de trois mécanismes de diffusion :

1. **Diffusion de surface** : Ce mécanisme représente la diffusion causée par la réflexion spéculaire des ondes radar sur des surfaces lisses, telles que les bâtiments ou les plans d'eau. La contribution de diffusion de surface est généralement associée aux éléments diagonaux de la matrice de covariance.
2. **Diffusion de double rebond** : Ce mécanisme est lié à la diffusion causée par des rebonds multiples entre des surfaces, comme dans le cas des coins ou des arêtes. La diffusion de double rebond est souvent associée aux éléments non diagonaux de la matrice de covariance.
3. **Diffusion de volume** : Ce mécanisme représente la diffusion causée par des objets volumétriques, tels que la végétation dense ou les forêts. La diffusion de volume est généralement associée aux éléments diagonaux de la matrice de covariance.

La décomposition en trois composantes, proposée par Freeman et Durden est utilisée pour décomposer la matrice de corrélation croisée interférométrique formée dans la base lexicographique.




FIGURE 1.10 – (a) Diffusion de surface (b) Diffusion de double rebond (c) Diffusion de volume

Par conséquent, le point de départ est la définition du vecteur cible dans la base lexicographique pour les deux extrémités de la ligne de base,  $k_{L1}$  et  $k_{L2}$ , donnée par [10] :

$$\vec{k}_{L1} = \begin{bmatrix} S_{VV1} \\ \sqrt{2}S_{VH1} \\ S_{HH1} \end{bmatrix} \quad \vec{k}_{L2} = \begin{bmatrix} S_{VV2} \\ \sqrt{2}S_{VH2} \\ S_{HH2} \end{bmatrix} \quad (1.50)$$

La matrice de corrélation croisée correspondante  $C_{int}$  est :

$$C_{int} = \begin{bmatrix} \langle S_{VV1}S_{VV2}^* \rangle & \langle \sqrt{2}S_{VV1}S_{VH2}^* \rangle & \langle S_{VV1}S_{HH2}^* \rangle \\ \langle \sqrt{2}S_{VH1}S_{VV2}^* \rangle & \langle S_{VH1}S_{VH2}^* \rangle & \langle \sqrt{2}S_{VH1}S_{HH2}^* \rangle \\ \langle S_{HH1}S_{VV2}^* \rangle & \langle \sqrt{2}S_{HH1}S_{VH2}^* \rangle & \langle S_{HH1}S_{HH2}^* \rangle \end{bmatrix} \quad (1.51)$$

Cette matrice sera exprimée comme la somme de trois matrices représentant les contributions du volume  $C_{VOL}$ , de la surface  $C_{ODD}$  et du dièdre (double rebond)  $C_{DBL}$ , tel que proposé par Freeman et Durden, mais ajoutées de manière cohérente dans ce cas.

$$C_{int} = C_{VOL} + C_{ODD} + C_{DBL} \quad (1.52)$$

Ensuite, la formulation des trois mécanismes de diffusion et la procédure pour les récupérer à partir des données seront examinées, en soulignant les nouveaux problèmes découlant de l'extension aux observables interférométriques. Il convient de noter qu'une corrélation nulle entre les canaux co-polarisés et croisés sera supposée.

- **Diffusion volumique** : La matrice de diffusion pour une particule dans le volume aléatoire est :

$$S_{vol_i} = \begin{bmatrix} S_{V_i} & 0 \\ 0 & S_{H_i} \end{bmatrix} \quad (1.53)$$

Où  $i = 1, 2$ , ce qui fait référence à chaque extrémité de la ligne de base. La distribution aléatoire de l'orientation de chaque particule à l'intérieur du volume est prise en compte

en modifiant la matrice  $S_{vol_i}$ .

$$S'_{vol_i} = \begin{bmatrix} \cos \phi & \sin \phi \\ -\sin \phi & \cos \phi \end{bmatrix} \quad S_{vol_i} = \begin{bmatrix} \cos \phi & -\sin \phi \\ \sin \phi & \cos \phi \end{bmatrix} \quad (1.54)$$

Si l'on suppose que l'ensemble des dipôles est caractérisé par la matrice de diffusion précédente et que l'angle d'orientation suit une loi uniforme, alors la matrice de covariance d'un ensemble de dipôles finis doit être comme suit :

$$C_{VOL} = F_V \begin{bmatrix} 1 & 0 & \frac{1}{3} \\ 0 & \frac{2}{3} & 0 \\ \frac{1}{3} & 0 & 1 \end{bmatrix} \quad (1.55)$$

$F_v$  est la contribution de diffusion volumique dans la composante  $|S_{VV}|^2$ .

- **Diffusion double rebond** : Cette contribution est modélisée par la matrice de diffusion dans pour les deux extrémités de la ligne de base.

$$S_{dbl_i} = \begin{bmatrix} e^{-j\gamma_{vi}} R_{gv} R_{tv} & 0 \\ 0 & e^{-j\gamma_{hi}} R_{gh} R_{th} \end{bmatrix} \quad (1.56)$$

Où  $i = 1, 2$ , et,  $R_{tv}$  et  $R_{th}$  sont les coefficients de Fresnel (ou de réflexions) correspond respectivement aux polarisations verticale et horizontale. La surface horizontale présente les coefficients  $R_{gh}$ ,  $R_{gv}$  pour les mêmes polarisations. Et  $\gamma_h$ ,  $\gamma_v$  sont les deux phases pour les polarisations horizontale et verticale.

Cette matrice de diffusion nous permet d'obtenir la matrice de covariance du mécanisme de diffusion de double rebond. Après avoir normalisé cette matrice par rapport à  $S_{vv}$ , la matrice de covariance sera :

$$C_{DBL} = F_d \begin{bmatrix} 1 & 0 & \alpha \\ 0 & 0 & 0 \\ \alpha^* & 0 & |\alpha|^2 \end{bmatrix} \quad (1.57)$$

Avec :

$$\alpha = \frac{R_{gh} R_{th}}{R_{gv} R_{tv}} e^{j\Delta\psi_{vh}} \quad (1.58)$$

$F_d$  est la contribution du processus de diffusion de type double rebond :  $F_d = |R_{gv} R_{tv}|^2$ .

- **Diffusion surfacique** : C'est le troisième et le dernier cas de la décomposition de Freeman, qui est modélisé par la diffusion de surface de Bragg de premier ordre. La

matrice de covariance correspondante est donnée par :

$$S_{ODD} = \begin{bmatrix} R_h & 0 \\ 0 & R_v \end{bmatrix} \quad (1.59)$$

Où  $R_h$ ,  $R_v$  Sont les coefficients de réflexion des ondes polarisées horizontalement et verticalement.

$$R_h = \frac{\cos \theta_i - \sqrt{\epsilon_r - \sin^2 \theta_i}}{\cos \theta_i + \sqrt{\epsilon_r - \sin^2 \theta_i}} \quad (1.60)$$

$$R_v = \frac{(\epsilon_r - 1)[\sin^2 \theta_i - \epsilon_r(1 + \sin^2 \theta_i)]}{\epsilon_r \cos \theta_i + \sqrt{\epsilon_r - \sin^2 \theta_i}} \quad (1.61)$$

$\theta_i$  : L'angle d'incidence local.

$\epsilon_r$  : Le constant d'électrique relatif de la surface (permittivité).

Donc, la matrice de covariance correspondante est représentée par :

$$C_{ODD} = F_s \begin{bmatrix} 1 & 0 & \beta \\ 0 & 0 & 0 \\ \beta^* & 0 & |\beta|^2 \end{bmatrix} \quad (1.62)$$

Avec :  $F_s = |R_v|^2$ ,  $\beta_s = \frac{R_h}{R_v}$

$F_s$  est La contribution de la diffusion surfacique dans la composante  $|S_{VV}|^2$ .

### 1.7.3 La différence entre les deux décompositions

La principale différence entre la décomposition de Yamaguchi et la décomposition de Freeman réside dans leur approche pour décomposer les matrices de cohérence ou de covariance des données polarimétriques.

La décomposition de Yamaguchi est une méthode incohérente qui décompose la matrice de cohérence en quatre puissances de diffusion correspondant à des mécanismes de diffusion spécifiques tels que la diffusion en surface, la diffusion en double rebond, la diffusion en volume et la diffusion en hélice. Cette décomposition est basée sur des modèles physiques et tient compte de l'analyse du voisinage des pixels pour prendre en compte les relations spatiales.

En revanche, la décomposition de Freeman est une méthode cohérente qui décompose la matrice de covariance en termes de puissances de diffusion cohérentes, telles que la puissance de diffusion en surface, la puissance de diffusion en double rebond, la puissance de diffusion en volume et la puissance de diffusion en hélice. Elle ne tient pas compte des

---

relations spatiales entre les pixels et suppose qu'un pixel ne contient qu'un seul type de mécanisme de diffusion.

## 1.8 conclusion

Dans ce premier chapitre, nous avons exploré les fondements des images SAR et leur pertinence dans l'extraction des zones urbaines. Nous avons examiné les principes de formation d'images SAR, mettant en évidence les avantages uniques de cette technologie en termes de capacité d'acquisition indépendamment des conditions météorologiques et d'illumination.

Nous avons également abordé l'importance de la polarimétrie dans l'analyse des images SAR urbaines. En utilisant les informations polarimétriques, nous pouvons obtenir des données plus riches et plus détaillées sur les caractéristiques des zones urbaines, ce qui facilite leur extraction et leur caractérisation.

De plus, nous avons exploré les décompositions planimétriques, en nous concentrant sur les méthodes de Yamaguchi et de Freeman. Ces décompositions nous permettent de séparer les contributions de différents types de rétrodiffusion, fournissant ainsi des informations plus précises sur les propriétés physiques des zones urbaines.

# Chapitre 2

## Méthodes de classification

### 2.1 Introduction

La classification est un processus de catégorisation des objets ou des données en fonction de leurs caractéristiques ou de leurs attributs. Elle permet de regrouper des éléments similaires dans des classes prédéfinies afin d'interpréter et d'identifier la nature des objets présents dans une image ou un ensemble de données observés par un radar. Il existe deux principales approches de classification : la classification non supervisée et la classification supervisée. La classification, étant un domaine essentiel de l'apprentissage automatique, permet de traiter de vastes ensembles de données et de fournir des informations précieuses pour la caractérisation et l'analyse des objets terrestres.

- **La classification non supervisée :**

La classification non supervisée est une approche de l'apprentissage automatique dans laquelle les données ne sont pas étiquetées et où l'objectif est d'identifier des structures ou des patterns intrinsèques au sein des données. Contrairement à la classification supervisée, il n'y a pas de variable de classe prédéfinie à prédire.

Dans la classification non supervisée, l'algorithme d'apprentissage examine les caractéristiques des données et tente de les regrouper en fonction de similarités ou de relations entre les exemples. Ces groupements, également appelés clusters, permettent de découvrir des structures cachées dans les données, ce qui peut aider à la compréhension et à l'exploration des données.

La classification non supervisée est souvent utilisée pour des tâches telles que la segmentation d'image, la recommandation de produits, l'analyse de données et d'autres applications où les classes ne sont pas connues à l'avance.

Citons quelques méthodes de classification non-supervisé :

- La décomposition de Freeman et Durden

- La décomposition de YAMAGUCHI
- Le seuillage de K-means
- Le seuillage d'OTSU

## 2.2 Les méthodes de classification non-supervisées

### 2.2.1 La méthode de seuillage

La méthode de seuillage est une technique de traitement d'images utilisée pour segmenter une image en différentes régions ou classes en fonction des niveaux de gris, des valeurs des pixels ou d'autres caractéristiques. Elle consiste à définir un seuil ou plusieurs seuils pour diviser les pixels de l'image en groupes distincts.

La méthode de seuillage fonctionne en comparant les valeurs des pixels de l'image avec le seuil défini. Les pixels ayant une valeur supérieure ou égale au seuil sont assignés à une classe, tandis que ceux ayant une valeur inférieure au seuil sont assignés à une autre classe. Cette approche permet de séparer les objets d'intérêt du reste de l'image en fonction de leur intensité ou de leur apparence.

Dans notre étude, on va étudier les méthodes de seuillage d'OTSU et de K-means qui sont deux techniques populaires utilisées dans le contexte de la méthode de seuillage.

#### 2.2.1.1 La méthode de seuillage de K-means

Le K-means est un algorithme de regroupement non supervisé largement utilisé dans l'analyse de données. L'objectif principal de cet algorithme est de partitionner un ensemble de données en  $K$  clusters distincts, où  $K$  est un nombre préalablement défini par l'utilisateur. Chaque cluster est caractérisé par un centroïde, qui représente le centre géométrique des points du cluster.

La méthode de K-means n'est pas directement considérée comme une méthode de seuillage, mais elle peut être utilisée pour effectuer une segmentation de seuillage de la manière suivante. En supposant qu'il y a  $m \times n$  pixels dans l'image avec des niveaux de gris  $[0, 1, \dots, L - 1]$ . Les niveaux de gris du pixel à la position  $(x, y)$  sont représentés par  $f(x, y)$ . Ensuite, l'image peut être présentée sous la forme d'une matrice de données [11] :

$$[F(x, y)]_N = [f(x, y)] \quad (2.1)$$

Avec :  $N = m \times n$

La méthode de K-means partitionne les points dans la matrice de données  $[F(x, y)]$  en  $k$  classes avec des centroïdes initiaux  $[ic_1, ic_2, \dots, ic_k]$  et des centroïdes finaux  $[cc_1, cc_2, \dots, cc_k]$ . La procédure de la méthode de K-means en tant que méthode de sélection de seuil peut

être exprimée comme suit :

1. **Initialisation** : Les  $K$  centroïdes initiaux sont généralement choisis de manière aléatoire parmi les données d'entrée ou en utilisant une heuristique spécifique.




FIGURE 2.1 – Tirage aléatoire des centres  $C_1^0$  et  $C_2^0$

2. **Attribution** : Chaque point de données est attribué au cluster dont le centroïde est le plus proche en termes de distance euclidienne. La distance entre un point et un centroïde est souvent calculée comme la distance euclidienne dans l'espace des caractéristiques.






FIGURE 2.2 – Constitution des classes  $I_1^0$  et  $I_2^0$

3. **Mise à jour du centroïde** : Les centroïdes des clusters sont mis à jour en recalculant les moyennes des points appartenant à chaque cluster. Les moyennes sont calculées dans chaque dimension de l'espace des caractéristiques.
4. **Répétition des étapes 2 et 3** : Les étapes d'attribution et de mise à jour du centroïde sont répétées jusqu'à ce qu'il y ait convergence, c'est-à-dire que les points ne changent plus de cluster ou que le critère d'arrêt prédéfini soit atteint (par exemple, un nombre maximum d'itérations).
5. **Trouver le seuil optimal (seuillage)** : Une fois que les clusters ont été formés, une approche courante consiste à utiliser les valeurs des centroïdes pour déterminer



FIGURE 2.3 – Nouveaux centres  $C_1^1$  et  $C_2^1$  et nouvelles classes  $I_1^1$  et  $I_2^1$  (2<sup>ème</sup> itération)FIGURE 2.4 – Nouveaux centres  $C_1^2$  et  $C_2^2$  et nouvelles classes  $I_1^2$  et  $I_2^2$  (3<sup>ème</sup> itération)

un seuil de séparation. Ce seuil peut être utilisé pour réaliser une segmentation de seuillage où les points d'une certaine classe sont considérés comme faisant partie du foreground et les points d'une autre classe sont considérés comme faisant partie du background.

Dans la méthode de seuillage bi-niveau, où  $k = 2$ , les niveaux de gris les plus petits et les plus grands de l'image sont sélectionnés comme les centroïdes initiaux. Le seuil  $t$  peut être obtenu en calculant la moyenne des centroïdes finaux.

La méthode de seuillage par k-means peut être étendue à une méthode de seuillage multiniveau en fixant  $k = M$ , où  $M - 1$  est le nombre de seuils. Dans cette méthode, nous ne sélectionnons pas les centroïdes initiaux de manière aléatoire comme d'habitude. La valeur des centroïdes initiaux  $ic_1$  et  $ic_k$  correspond aux niveaux de gris les plus petits et les plus grands de l'image ; le  $i_{eme}$  centroïde initial est défini comme suit :

$$ic_i = ic_1 + \frac{ic_k - ic_1}{k - 1} \times (i - 1) \quad (2.2)$$

Avec :  $1 < i < k$

Les  $j_{\text{emes}}$  seuils  $t_j$  sont sélectionnés comme suit :

$$t_j = 0.5(cc_j + cc_{j+1}) \quad (2.3)$$

Avec :  $1 \leq j \leq k - 1$

Il convient de souligner que les résultats du regroupement de K-means maintiennent l'ordre des centroïdes initiaux par rapport à un ensemble de données unidimensionnelles. Par conséquent, on a  $t_j < t_{j+1}$  pour  $1 \leq j \leq k - 2$ .

### 2.2.1.2 La méthode de seuillage d'OTSU

La méthode d'OTSU, également connue sous le nom de seuillage d'OTSU, est une technique de seuillage automatique largement utilisée en traitement d'images. Elle vise à trouver le seuil optimal pour binariser une image en maximisant la variance interclasse ou en minimisant la variance intraclasse.

L'idée principale de la méthode d'OTSU est de considérer chaque niveau de gris de l'image comme un seuil potentiel, puis de calculer la variance interclasse pour chaque seuil. La variance interclasse mesure la séparation des niveaux de gris en classes d'objets et de fond, et un seuil est considéré comme optimal lorsque la variance interclasse est maximisée.

Afin de mieux présenter cette méthode, on suppose qu'une image est représentée avec  $L$  niveaux de gris  $[0, 1, \dots, L - 1]$ . Le nombre de pixels au niveau  $i$  est représenté par  $n_i$ , et le nombre total de pixels est représenté par  $N = n_1 + n_2 + \dots + n_L$ . La probabilité du niveau de gris  $i$  est représentée par [11] [12] :

$$p_i = \frac{n_i}{N}, p_i \geq 0 \sum_0^{L-1} p_i = 1 \quad (2.4)$$

Dans la méthode de seuillage bi-niveau, les pixels de l'image sont divisés en deux classes  $C_1$  avec des niveaux de gris  $[0, 1, \dots, t]$  et  $C_2$  avec des niveaux de gris  $[t + 1, \dots, L - 1]$  en utilisant le seuil  $t$ . Les distributions de probabilité des niveaux de gris pour les deux classes sont :

$$w_1 = Pr(C_1) = \sum_{i=0}^t p_i \quad (2.5)$$

$$w_2 = Pr(C_2) = \sum_{i=t+1}^{L-1} p_i \quad (2.6)$$




FIGURE 2.5 – Exemple des pixels d'une image et son niveau de Gray correspondant

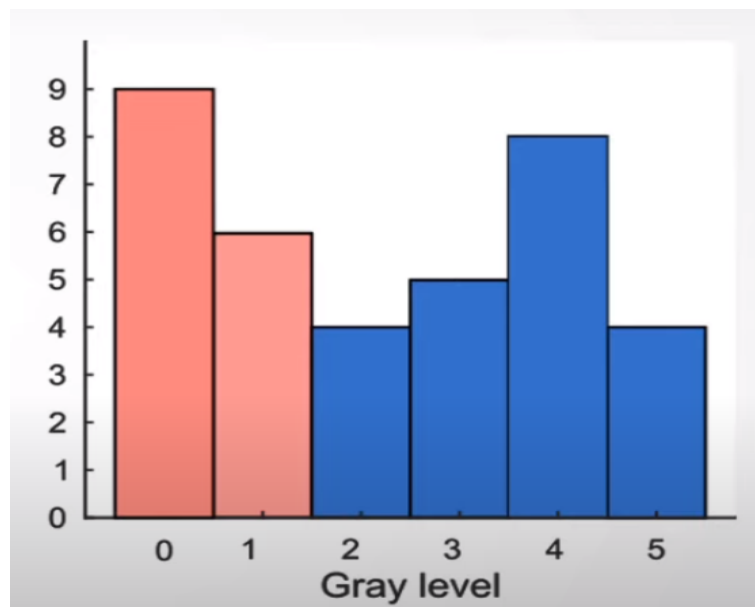


FIGURE 2.6 – La déviation en deux classes en utilisant le seuille d'Otsu

Les moyennes de la classe  $C_1$  et de la classe  $C_2$  sont :

$$u_1 = \frac{\sum_{i=0}^t ip_i}{w_1} \quad (2.7)$$

$$u_2 = \frac{\sum_{i=t+1}^{L-1} ip_i}{w_2} \quad (2.8)$$

La moyenne totale des niveaux de gris est représentée par  $u_T$  :

$$u_T = w_1 u_1 + w_2 u_2 \quad (2.9)$$

Dans notre exemple :

• **Background :**

$$w_b = \frac{9+6}{36} = 0.42$$

$$u_b = \frac{(9 \times 0) + (6 \times 1)}{9+6} = 0.4$$

Les variances des classes sont :

• **Foreground :**

$$w_f = \frac{4+5+8+4}{36} = 0.58$$

$$u_f = \frac{(4 \times 2) + (5 \times 3) + (8 \times 4) + (4 \times 4)}{4+5+8+4} = 3.57$$

$$\sigma_1^2 = \frac{\sum_{i=0}^t (i - u_1)^2 p_i}{w_1} \quad (2.10)$$

$$\sigma_2^2 = \frac{\sum_{i=t+1}^{L-1} (i - u_2)^2 p_i}{w_2} \quad (2.11)$$

La variance interclasses est :

$$\sigma_B^2 = w_1 (u_1 - u_T)^2 + w_2 (u_2 - u_T)^2 \quad (2.12)$$

La variance intraclasses est :

$$\sigma_W^2 = \sum_{k=1}^M w_k \sigma_k^2 \quad (2.13)$$

La variance totale des niveaux de gris est :

$$\sigma_T^2 = \sigma_w^2 + \sigma_B^2 \quad (2.14)$$

La méthode d'OTSU utilise donc un algorithme itératif pour explorer tous les seuils possibles et trouver celui qui maximise la variance interclasse (comme indiqué dans le tableau ci-dessous). Une fois le seuil optimal trouvé, l'image est binarisée en attribuant les niveaux de gris au-dessus du seuil à la classe des objets (foreground class) et ceux en dessous du seuil à la classe du fond (background class).

$l_t$	0	1	2	3	4	5
$W_b$	0	0.25	0.42	0.53	0.67	0.89
$\mu_b$	0	0	0.40	0.74	1.21	1.91
$W_f$	1	0.75	0.58	0.47	0.33	0.11
$\mu_f$	2.25	3.00	3.57	3.94	4.33	5.00
$\sigma_b^2$	0	1.69	2.44	2.56	2.17	0.95

FIGURE 2.7 – Tableau des calculs des variances




FIGURE 2.8 – Résultat final de l'image après le seuillage d'Otsu

**Note :**

- La variance est une mesure statistique de la dispersion ou de la variabilité des valeurs d'un ensemble de données par rapport à leur moyenne. Elle indique à quel point les données sont écartées de leur valeur moyenne.
- La variance interclasse mesure la dispersion des valeurs de pixel entre les deux classes. En maximisant la variance interclasse, nous cherchons à trouver le seuil qui maximise la différence entre les deux classes, rendant ainsi la segmentation plus claire.
- La variance intraclasse, quant à elle, mesure la dispersion des valeurs de pixel à l'intérieur de chaque classe. En minimisant la variance intraclasse, nous cherchons à obtenir une homogénéité maximale à l'intérieur de chaque classe.

**Remarque :** La méthode d'Otsu peut être étendue à une méthode de seuillage à plusieurs niveaux « multi-classes » (c'est le cas dans notre étude, on a classé trois classes).

- **La classification supervisée :**

La classification supervisée est l'une des approches les plus couramment utilisées en apprentissage automatique. Elle implique un processus d'apprentissage dans lequel un algorithme est entraîné sur un ensemble de données d'apprentissage étiquetées, c'est-à-dire des exemples pour lesquels on connaît déjà la classe à laquelle ils appartiennent. L'objectif est de développer un modèle qui peut prédire correctement la classe d'exemples non étiquetés.

Dans la classification supervisée, chaque exemple d'apprentissage est constitué de caractéristiques (ou attributs) et d'une étiquette de classe correspondante. L'algorithme d'apprentissage utilise ces exemples pour apprendre une fonction qui peut mapper les caractéristiques aux étiquettes de classe. Une fois que le modèle est entraîné, il peut être utilisé pour prédire la classe de nouveaux exemples.

Citons quelques méthodes de classification supervisées :

- La méthode de classification SVM (Support Vector Machine).
- La méthode de classification MLP (Multi Layer Perceptron)
- La méthode de classification RANDOM FOREST

## 2.3 Les méthodes de classification supervisées

### 2.3.1 La méthode de classification SVM (Support Vector Machine)

Le Support Vector Machine (SVM) est un algorithme d'apprentissage supervisé utilisé pour la classification et la régression. Il est largement utilisé dans le domaine de l'apprentissage automatique en raison de sa capacité à traiter efficacement des problèmes de classification complexes.

L'objectif principal du SVM est de trouver un hyperplan optimal qui sépare les exemples de différentes classes dans un espace multidimensionnel. Cet hyperplan de décision permet de classifier de nouveaux exemples en fonction de leur position relative par rapport à l'hyperplan. L'idée centrale du SVM est de maximiser la marge entre les exemples de support (également appelés vecteurs de support) et l'hyperplan de décision. Les vecteurs de support sont les exemples d'entraînement les plus proches de l'hyperplan et jouent un rôle essentiel dans la définition de l'hyperplan optimal.

L'un des principaux avantages du SVM est sa capacité à généraliser à partir d'un ensemble d'exemples d'apprentissage restreint. Cela signifie qu'il est capable de classifier

avec précision de nouveaux exemples qui n'ont pas été utilisés lors de l'apprentissage. Cela en fait un outil puissant pour la classification de données complexes et la résolution de problèmes de classification à grande échelle.

Le SVM utilise différentes techniques pour traiter des données linéairement séparables ou non linéairement séparables. Dans le cas de données linéairement séparables, un hyperplan linéaire est suffisant pour la classification. Cependant, lorsque les données sont non linéairement séparables, le SVM utilise des noyaux pour projeter les données dans un espace de dimension supérieure, où elles peuvent être linéairement séparables [13].

- **Premier cas** : classes linéairement séparables

Supposons qu'on dispose d'un ensemble de données représentant des avions avec deux attributs : la vitesse maximale et la portée de vol. Notre objectif est de classer ces avions en deux catégories : "avion de chasse" et "avion de ligne" en construisant un hyperplan linéaire  $f(x) = w_T \phi(x) + b$  qui permet de prédire la classe des avions selon la règle de classification :

$$g(x) = \begin{cases} +1 & \text{si } f(x) > 0 \\ -1 & \text{si } f(x) < 0 \end{cases} \quad (2.15)$$

Dans notre exemple :

Si :  $f(x) > 0$  donc : cette classe correspond à des avions de chasse

Si :  $f(x) < 0$  donc : cette classe correspond à des avions de ligne




FIGURE 2.9 – deux classes linéairement séparables

On remarque qu'on peut tracer plusieurs hyper-plans de séparation parfaites des classes, mais notre objectif est de trouver l'hyper-plan qui maximise la marge entre les points des deux classes en trouvant le poids optimal de ce dernier et en utilisant des techniques d'optimisations numérique tel que la décente de gradient.

Ainsi que, Les points de support sont importants car ils sont les plus difficiles à classer. Ils sont situés à proximité de la frontière de décision, où les classes se chevauchent ou sont mal séparées. En se concentrant sur ces points, le SVM vise à maximiser la marge, c'est-à-dire la distance entre les points de support et l'hyperplan. Cela permet de garantir une séparation optimale entre les classes et une meilleure capacité de généralisation du modèle.

L'utilisation des points de support permet également de rendre l'algorithme SVM plus efficace en réduisant le nombre total de vecteurs nécessaires pour définir l'hyperplan. Cela permet d'économiser en termes de mémoire et de temps de calcul lors de l'application du modèle à de nouveaux exemples.




FIGURE 2.10 – Processus de maximisation de la marge [6]

Une fois que l'hyperplan de décision est trouvé, on peut classifier de nouveaux exemples en les projetant dans cet espace défini par les attributs et en déterminant de quel côté de l'hyperplan ils se trouvent. Si un exemple se situe du côté "avion de chasse" de l'hyperplan, il sera classé comme un avion de chasse, et s'il se situe du côté "avion de ligne" de l'hyperplan, il sera classé comme un avion de ligne.

- **Deuxième cas** : classes non linéairement séparables

La méthode de classification non linéaire dans le cadre de SVM vise à résoudre des problèmes de classification où les données ne sont pas linéairement séparables dans l'espace d'origine. Contrairement à la classification SVM linéaire, qui utilise un hyperplan linéaire pour séparer les classes, la classification non linéaire utilise des transformations de données pour projeter les exemples dans un espace de dimension supérieure où ils peuvent être linéairement séparables. Comme on peut voir dans l'exemple présenté par la figure 2.11, il est impossible de trouver un hyper-plan linéaire qui sépare ces deux classes.

L'idée centrale de la classification non linéaire dans SVM est d'appliquer une fonction de transformation, appelée fonction noyau (kernel function), aux données d'entrée. Cette fonction noyau permet de calculer les produits scalaires dans l'espace de dimen-






FIGURE 2.11 – Deux classes non linéairement séparables

sion supérieure sans avoir à effectuer explicitement la transformation. Ainsi, le modèle SVM peut être entraîné dans cet espace de dimension supérieure sans nécessiter une connaissance directe de cette transformation.




FIGURE 2.12 – Projection non linéaire des points. En bleu, la fonction de décision linéaire en 3D

L'utilisation de fonctions noyau permet au SVM de capturer des structures de décision complexes et non linéaires dans les données. Certains exemples couramment utilisés de fonctions noyau incluent le noyau gaussien (ou RBF, Radial Basis Function), le noyau polynômial et le noyau sigmoïde. Chaque type de noyau a ses propres propriétés et peut être choisi en fonction des caractéristiques des données et du problème de classification spécifique.

La classification non linéaire dans SVM suit généralement les mêmes étapes que la classification linéaire, avec la différence qu'elle utilise une fonction noyau appropriée lors de




FIGURE 2.13 – La fonction sigmoïde

la construction de l'hyperplan de décision. Les étapes typiques comprennent la collecte des données d'apprentissage, le choix d'une fonction noyau appropriée, l'optimisation des paramètres du modèle à l'aide d'un algorithme d'optimisation, et l'évaluation et la prédiction des nouvelles données.




FIGURE 2.14 – La fonction de décision non linéaire

- **Troisième cas** : classification SVM multi classes

Le SVM peut également être utilisé pour des problèmes de classification multi-classes. Il existe différentes approches pour étendre la classification SVM linéaire à plusieurs classes, notamment la méthode One-vs-All (OVA) et la méthode One-vs-One (OVO).

Dans la méthode OVA, on entraîne un classifieur SVM pour chaque classe en la considérant comme la classe positive et toutes les autres classes comme négatives. Lors de la classification, l'exemple est attribué à la classe correspondante au classifieur avec la plus grande valeur de décision.

Dans la méthode OVO, on entraîne un classifieur SVM pour chaque paire de classes possibles. Lors de la classification, l'exemple est attribué à la classe qui remporte le plus

de votes parmi tous les classifieurs.

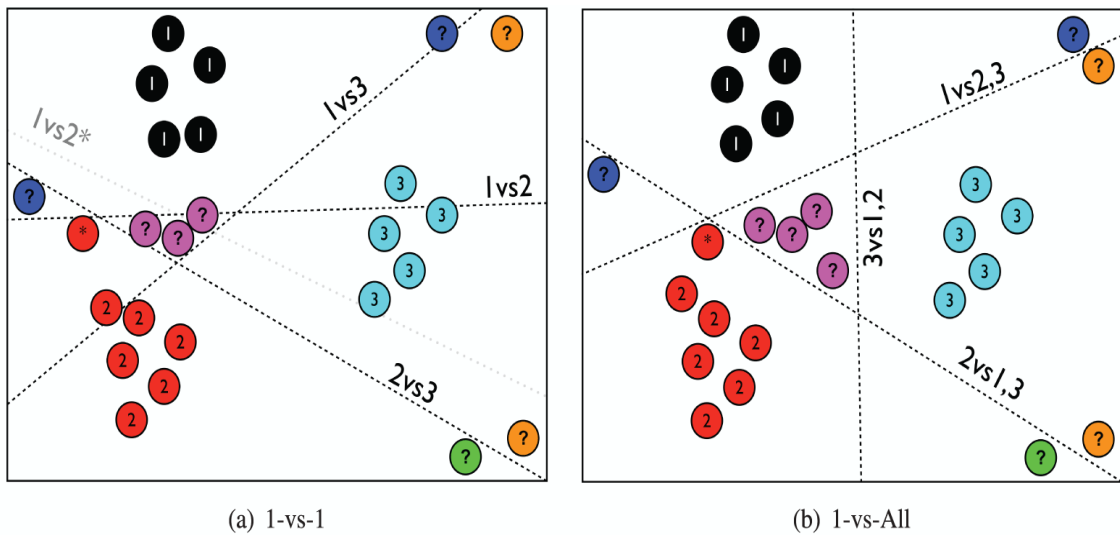


FIGURE 2.15 – Méthodes OVA et OVO

### 2.3.2 La méthode de classification MLP (Multi Layer Perceptron)

La classification MLP (Multi Layer Perceptron) est une méthode d'apprentissage automatique utilisée pour la classification de données. Le MLP fait partie de l'intelligence artificielle (IA) et plus précisément du domaine du machine learning (figure 2.16).

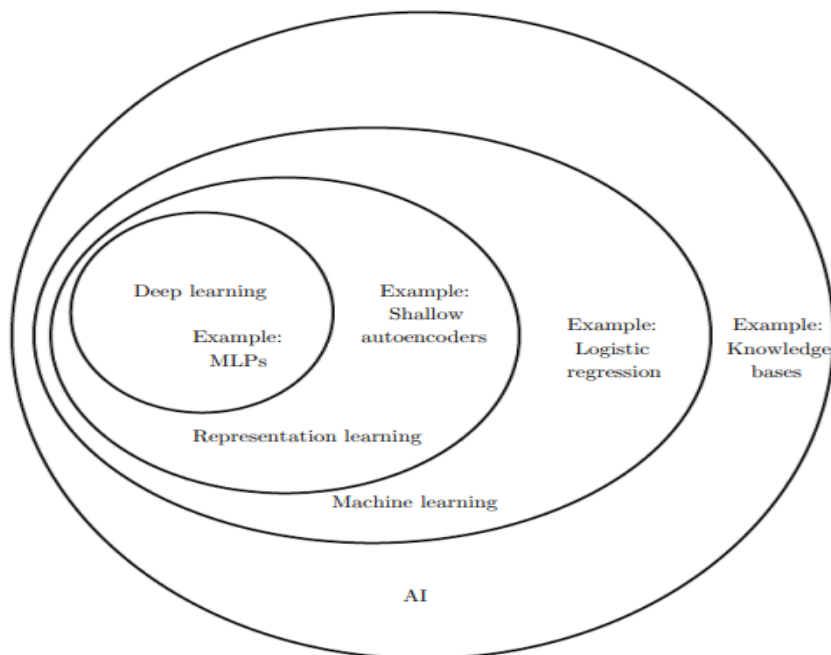


FIGURE 2.16 – Relation entre le MLP et le IA [7]

Il s'agit d'un type de réseau de neurones artificiels, également appelé réseau neuronal feedforward (Deep Feedforward Networks ou Feedforward Neural Networks), qui est composé de plusieurs couches de neurones interconnectés. Le MLP appartient à la branche du machine learning, qui se concentre sur l'apprentissage à partir de données pour effectuer des prédictions ou des classifications. Il utilise des algorithmes d'apprentissage supervisé pour ajuster les poids des neurones afin de trouver des modèles et des relations dans les données d'entrée.




FIGURE 2.17 – Diagramme du Perceptron Multi-Couches (MLP) avec quatre couches cachées.

Pour qu'on puisse réaliser la multi layer perceptron classification, il y a des étapes principales à suivre.

Ces étapes principales sont :

### 1. Présentation des données :

Les données d'entraînement doivent être préparées en les divisant en ensembles d'entraînement et de test, en normalisant les caractéristiques si nécessaire, et en effectuant d'autres prétraitements nécessaires.

### 2. Architecture du réseau :

On définit l'architecture du réseau MLP en spécifiant le nombre de couches cachées et le nombre de neurones dans chaque couche. Les couches cachées sont responsables de l'extraction des caractéristiques des données.

Citons quelques types d'architecture MLP :

- **MLP à une seule couche cachée** : Cette architecture comprend une couche d'entrée, une couche cachée et une couche de sortie. Le nombre de neurones dans la couche cachée peut varier en fonction des besoins du problème. C'est l'architecture la plus simple et elle est souvent utilisée pour des tâches de classification simples.
- **MLP à plusieurs couches cachées** : Cette architecture comprend une couche d'entrée, plusieurs couches cachées et une couche de sortie. Chaque couche cachée est composée de plusieurs neurones interconnectés. Cette architecture permet d'apprendre des représentations hiérarchiques des données et est utilisée pour des problèmes plus complexes nécessitant une modélisation plus profonde.
- **MLP avec connexions résiduelles** : Les connexions résiduelles sont des connexions directes qui permettent à l'information de sauter une ou plusieurs couches. Cette architecture favorise le flux d'information et facilite l'apprentissage en profondeur. Elle est utilisée pour améliorer les performances et la stabilité des MLP avec plusieurs couches cachées.
- **MLP avec régularisation** : Pour éviter le surapprentissage (overfitting), diverses techniques de régularisation peuvent être appliquées aux MLP. Cela peut inclure l'utilisation de la régularisation L1 ou L2, la régularisation dropout, ou d'autres techniques visant à réduire la complexité du modèle et à améliorer sa généralisation.

Il convient de noter que les architectures des MLP peuvent être adaptées en fonction du problème spécifique à résoudre. Le choix de l'architecture dépend de la complexité des données, de la disponibilité des ressources de calcul et des performances souhaitées.

### 3. Initialisation des poids :

Les poids des connexions entre les neurones sont initialisés de manière aléatoire ou selon une certaine distribution. Ces poids sont ajustés lors de l'apprentissage pour minimiser l'erreur de prédiction.

### 4. Propagation avant (forward propagation) :

Les données d'entrée sont propagées à travers le réseau en utilisant des opérations linéaires et des fonctions d'activation pour calculer les valeurs de sortie des neurones. Cela se fait couche par couche, en commençant par la couche d'entrée et en passant par les couches cachées jusqu'à la couche de sortie.

#### Note :

La fonction d'activation est une fonction mathématique appliquée à la sortie d'un neurone dans un réseau de neurones, qui permet d'introduire une non-linéarité dans le modèle. Elle est appliquée pour introduire des comportements non linéaires dans le réseau et permettre au modèle d'apprendre des relations complexes entre les entrées




FIGURE 2.18 – Forward propagation

et les sorties.

Citons quelques types de fonctions d'activation :

- **Fonction Sigmoidé** : La fonction sigmoïde est définie comme  $f(x) = \frac{1}{1 + \exp(-x)}$ . Elle produit une sortie dans l'intervalle  $(0, 1)$ , ce qui la rend adaptée pour les problèmes de classification binaire ou pour modéliser des probabilités.




FIGURE 2.19 – Fonction sigmoïde

- **Fonction Tanh** : La fonction tanh (tangente hyperbolique) est définie comme  $f(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)}$ . Elle produit une sortie dans l'intervalle  $(-1, 1)$ , ce qui lui permet de gérer des valeurs négatives.




FIGURE 2.20 – La fonction tanh

– **Fonction ReLU (Rectified Linear Unit) :**

La fonction ReLU est définie comme  $f(x) = \max(0, x)$ . Elle renvoie simplement la valeur d'entrée si elle est positive, et zéro sinon. La fonction ReLU est largement utilisée dans les réseaux de neurones profonds en raison de sa simplicité et de son efficacité de calcul.




FIGURE 2.21 – La fonction *RELU*

Le choix de la fonction d'activation dépend du problème et de la nature des données. Différentes fonctions d'activation peuvent avoir des effets différents sur l'apprentissage du modèle et peuvent être plus adaptées à certains types de problèmes.

5. **Calcul de l'erreur :**

L'erreur entre les prédictions du réseau et les étiquettes réelles est calculée à l'aide d'une fonction de perte, telle que la fonction d'erreur quadratique moyenne (Mean Squared Error, MSE). D'une autre façon, dans cette partie de processus on mesure la performance de modèle.

**Note :**

La fonction d'erreur (loss function) est une fonction mathématique utilisée pour quantifier la différence entre les prédictions du modèle et les valeurs réelles des données. Il existe plusieurs fonctions d'erreur couramment utilisées dans l'apprentissage automatique et la classification MLP.

Citons quelques types de fonctions d'erreur :

– **Erreur quadratique moyenne (Mean Squared Error, MSE) :**

Cette fonction d'erreur calcule la moyenne des carrés des différences entre les prédictions et les valeurs réelles. Elle est souvent utilisée pour les problèmes de régression. Elle est donnée par l'équation suivante :

$$MSE_{test} = \frac{1}{m} \sum_i (y'^{(test)} - y^{(test)})_i^2 \quad (2.16)$$

Où :

$m$  : est le nombre d'échantillons dans le jeu de données.

$y$  : représente les valeurs réelles de la variable cible.

$y'$  : représente les valeurs prédites par le modèle .

– **Erreur logarithmique (Log Loss) :**

Cette fonction d'erreur est utilisée principalement pour les problèmes de classification binaire. Elle mesure la performance du modèle en utilisant les probabilités prédites et les étiquettes réelles, en prenant en compte la confiance des prédictions.

Elle est donnée par :

$$\log loss = -\left(\frac{1}{m}\right) \sum (y \log(y') + (1 - y) \log(1 - y')) \quad (2.17)$$

– **Erreur de la cross-entropie (Cross-Entropy Loss) :**

Cette fonction d'erreur est utilisée pour les problèmes de classification multi-classes. Elle mesure la divergence entre la distribution de probabilité prédite par le modèle et la distribution réelle des étiquettes. Elle est donnée par :

$$Cross - EntropyLoss = -\left(\frac{1}{m}\right) \sum (y \log(y')) \quad (2.18)$$

– **Erreur de la log-vraisemblance négative (Negative Log-Likelihood Loss) :**

Cette fonction d'erreur est également utilisée pour les problèmes de classification multi-classes. Elle mesure la différence entre la log-vraisemblance des prédictions du modèle et la log-vraisemblance des étiquettes réelles. Elle est donnée par :

$$NegativeLog - likelihoodLoss = -\left(\frac{1}{m}\right) \sum \log(y') \quad (2.19)$$

Ces fonctions d'erreur sont utilisées pour guider l'optimisation du modèle lors de la rétropropagation des erreurs et la mise à jour des poids. Le choix de la fonction d'erreur dépend du type de problème et des objectifs spécifiques de l'apprentissage.

## 6. Rétropropagation (backpropagation) :

L'erreur est propagée en sens inverse à travers le réseau, de la couche de sortie vers la couche d'entrée, pour mettre à jour les poids des connexions. Cela se fait en utilisant la dérivée de la fonction de perte par rapport aux poids. Ce processus est utilisé pour minimiser l'erreur de prédiction du modèle.






FIGURE 2.22 – Rétropropagation (backpropagation)

**Note :**

Il existe plusieurs algorithmes d'optimisation utilisés pour ajuster les poids des connexions dans les réseaux de neurones, y compris les MLP. Voici quelques-uns des algorithmes d'optimisation couramment utilisés :

– **Descente de gradient (Gradient Descent) :**

C'est l'algorithme d'optimisation de base utilisé dans la rétropropagation. Il consiste à ajuster les poids dans la direction opposée du gradient de l'erreur par rapport aux poids. Il existe plusieurs variantes de la descente de gradient, telles que la descente de gradient stochastique (Stochastic Gradient Descent, SGD), la descente de gradient par mini-lots (Mini-batch Gradient Descent) et la descente de gradient avec moment (Gradient Descent with Momentum).




FIGURE 2.23 – Descente de gradient

– **RMSprop (Root Mean Square Propagation) :**

Cet algorithme d'optimisation ajuste également les taux d'apprentissage pour chaque poids, mais il utilise une moyenne mobile pondérée des carrés des gradients pour adapter les taux d'apprentissage de manière adaptative.

Chaque algorithme a ses propres avantages et inconvénients, et le choix dépend souvent du problème spécifique et des performances attendues.

#### 7. Répétition des étapes 4 à 7 :

Les étapes de propagation avant, calcul de l'erreur, rétropropagation et mise à jour des poids sont répétées pour un certain nombre d'itérations ou jusqu'à ce que la convergence soit atteinte.

#### 8. Évaluation et prédiction :

Cette étape est la dernière dans le processus de classification MLP. Une fois que le réseau a été entraîné, il peut être utilisé pour prédire les étiquettes des nouvelles données en effectuant une propagation avant avec les nouvelles données en entrée.

### 2.3.3 La méthode de classification random forest

Random forest (foret aléatoire) est un algorithme d'apprentissage automatique utilisé pour la classification et la régression. Il est basé sur le concept d'ensemble d'arbres de décision et utilise une combinaison de plusieurs arbres de décision pour effectuer des prédictions [14].

A cet effet, il est important de décrire le processus de formation d'un arbre de décision (decision tree).

- **Arbre de décision (decision tree) :**

Un arbre de décision commence par un premier nœud qui est appelé le nœud racine (root node) et qui représente l'ensemble des données d'entraînement et qui se divise en deux sous-nœuds en utilisant le processus de « splitting ». Si le sous-nœud (il est aussi appelé le nœud parent ou parent node) encore une fois se divise en d'autres sous-nœuds, il est donc appelé le nœud de décision (decision node), sinon il est appelé nœud terminale ou une feuille (Leaf ou terminal nœud) (ou l'enfant d'un nœud parent child of a parent node). On appelle l'ensemble de « decision node » et les « terminal node » une branche ou sous-arbre. (Figure 2.24)

La classification des exemples se fait en les triant dans l'arbre de la racine (root node) jusqu'à un nœud terminal (terminal node). Chaque nœud agit comme un cas de test pour un attribut et chaque bord descendant du nœud correspond aux réponses possibles au cas de test.

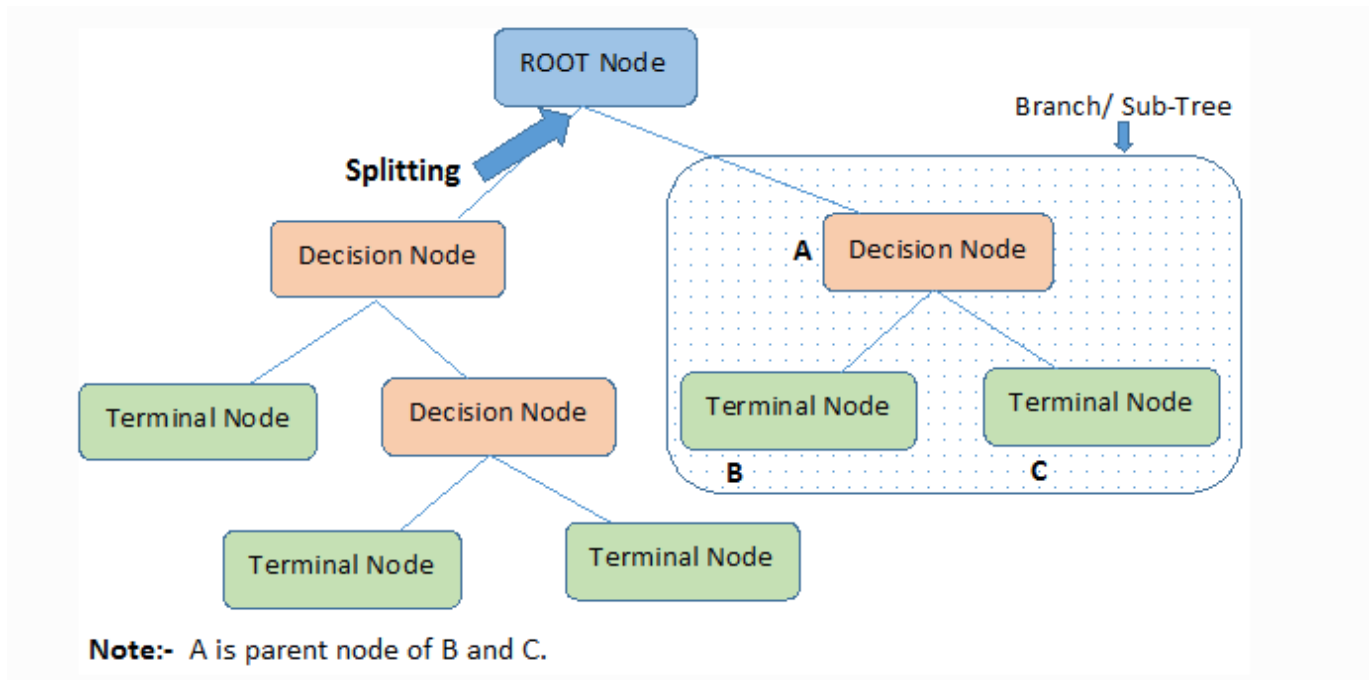


FIGURE 2.24 – Arbre de décision

Les arbres de décision utilisent plusieurs algorithmes pour décider de diviser un noeud en deux ou plusieurs sous-noeuds. La création de sous-noeuds augmente l'homogénéité des sous-noeuds résultants. En d'autres termes, on peut dire que la pureté du noeud augmente par rapport à la variable cible. L'arbre de décision divise les noeuds sur toutes les variables disponibles, puis sélectionne le split qui donne les sous-noeuds les plus homogènes.

Citons quelques algorithmes utilisés dans les arbres de décision :

- ID3 (Iterative Dichotomiser)
- C4.5 (le successeur de ID3)
- CART (Classification And Regression Tree)
- MARS (Multivariate Adaptive Regression Splines)

Le plus utilisé est le ID3 car il choisit le choix qui semble être le meilleur à ce moment. Le choix de test est crucial car si on choisit aléatoirement un noeud racine (root), cela peut nous donner des mauvais résultats avec une faible précision. Ces algorithmes prennent en considération des critères à suivre tels que :

– **L'entropie :**

L'entropie est une mesure du degré de désordre ou d'incertitude dans les informations traitées. Plus l'entropie est élevée, plus il est difficile de tirer des conclusions à partir de ces informations. Lancer une pièce de monnaie est un exemple d'action qui fournit des informations aléatoires.

Comme on peut voir dans le graph à coté, il est évident que l'entropie  $H(X)$  est

nulle lorsque la probabilité est soit de 0, soit de 1. L'entropie est maximale lorsque la probabilité est de 0,5 car cela représente un parfait aléatoire dans les données et il n'y a aucune chance de déterminer parfaitement le résultat.




FIGURE 2.25 – L'entropie

Mathématiquement, l'entropie pour un attribut est représentée de la manière suivante :

$$E(S) = \sum_{i=1}^c -p_i \log_2 p_i \quad (2.20)$$

Mathématiquement, l'entropie pour plusieurs attributs est représentée de la manière suivante :

$$E(T, X) = \sum_{c \in X} P(c) E(c) \quad (2.21)$$

– **Le gain d'information :**

Le gain d'information (Information Gain ou IG) est une mesure statistique qui évalue la capacité d'un attribut donné à séparer les exemples d'entraînement en fonction de leur classification cible. La construction d'un arbre de décision consiste à trouver un attribut qui offre le gain d'information le plus élevé et l'entropie la plus faible.

Le gain d'information est une diminution de l'entropie. Il calcule la différence entre l'entropie avant la division et l'entropie moyenne après la division de l'ensemble de données en fonction des valeurs des attributs donnés. L'algorithme de l'arbre de décision ID3 (Iterative Dichotomiser) utilise le gain d'information.




FIGURE 2.26 – Gain d'information

Mathématiquement, il est présenté comme suit :

$$\text{InformationGain}(T, X) = \text{Entropy}(T) - \text{Entropy}(T, X) \quad (2.22)$$

Le problème courant avec les arbres de décision, en particulier lorsque l'on dispose d'un tableau rempli de colonnes, c'est qu'ils peuvent s'adapter excessivement aux données d'entraînement. Parfois, il semble que l'arbre ait mémorisé l'ensemble des données d'entraînement. Si aucune limite n'est fixée sur un arbre de décision, il vous donnera une précision de 100% sur l'ensemble des données d'entraînement, car dans le pire des cas, il finira par créer une feuille distincte pour chaque observation. Cela a donc un impact sur la précision lors de la prédiction d'échantillons qui ne font pas partie de l'ensemble d'entraînement.

C'est pourquoi, pour éviter le surapprentissage (overfitting) on utilise le **Random Forest**.

Le processus de random forest est comme suit :

1. **Ensemble d'arbres de décision** : Random Forest crée un ensemble d'arbres de décision indépendants les uns des autres.
2. **Échantillonnage aléatoire** : Pour chaque arbre de décision de l'ensemble, un échantillon aléatoire (avec remplacement) est prélevé à partir de l'ensemble de données d'entraînement. Cela signifie que chaque arbre est entraîné sur un sous-ensemble différent des données.
3. **Sélection aléatoire des caractéristiques** : Lors de la création de chaque arbre de décision, un sous-ensemble aléatoire des caractéristiques est sélectionné pour la construction du modèle. Cela permet d'introduire de la variabilité et d'éviter la sur-apprentissage (overfitting).

4. **Construction des arbres de décision** : Chaque arbre de décision est construit en divisant récursivement les données d'entraînement en sous-ensembles plus petits en fonction des caractéristiques sélectionnées. Les divisions sont basées sur des critères tels que l'indice de Gini ou l'entropie pour maximiser la pureté des nœuds.
5. **Agrégation des prédictions** : Une fois que tous les arbres de décision ont été construits, les prédictions de chaque arbre sont agrégées pour obtenir une prédiction finale. Pour la classification, il peut s'agir d'un vote majoritaire des classes prédites par les arbres. Pour la régression, il peut s'agir d'une moyenne des valeurs prédites.

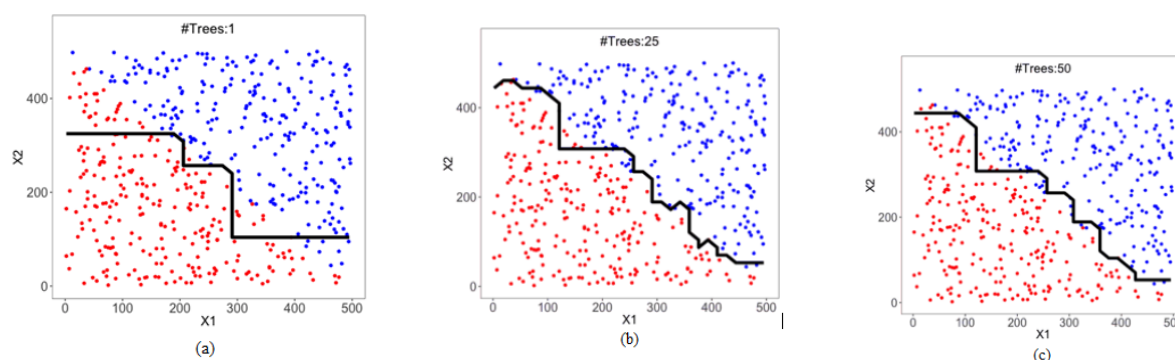


FIGURE 2.27 – (a) une seule arbre de décision (b) 25 arbres de décision (c) 50 arbres de décision

On remarque que, plus le nombre d'arbres de décision augmente plus les résultats sont fiables.

## 2.4 Comparaison entre ces méthodes de classification

La performance de ces méthodes de classification peut varier en fonction de nombreux facteurs, tels que la qualité des données, la taille de l'échantillon d'apprentissage, la sélection des caractéristiques et les paramètres de chaque algorithme.

- **SVM (Support Vector Machine) :**

Les avantages	Les inconvénients
Convient aux problèmes de classification binaire et multi-classe.	Peut être sensible au choix des hyperparamètres.
Bonne performance dans des espaces de grande dimension.	Peut nécessiter un temps de calcul élevé pour de grandes quantités de données.
Robuste aux valeurs aberrantes.	Peut être sensible aux valeurs manquantes dans les données.
Capacité à gérer des ensembles de données avec des caractéristiques continues et catégorielles.	
Possibilité d'utiliser des fonctions noyau pour capturer des relations non linéaires entre les données.	

- **MLP (Multi Layer Perceptron) :**

Les avantages	Les inconvénients
Capable de modéliser des relations complexes entre les caractéristiques d'entrée et les étiquettes de sortie.	Peut être sensible au surapprentissage (overfitting) si le modèle est trop complexe.
Convient aux problèmes de classification binaire et multi classe.	Requiert un grand nombre de données d'entraînement pour obtenir de bonnes performances.
Peut être utilisé pour la régression.	Peut nécessiter un temps de calcul élevé pour l'entraînement du modèle.
Robuste à la présence de données manquantes.	
Peut être utilisé avec des fonctions d'activation non linéaires pour capturer des motifs non linéaires.	

- **Random forest :**

Les avantages	Les inconvénients
Capable de gérer des ensembles de données avec un grand nombre de caractéristiques.	Moins interprétable que les modèles à base de règles, tels que les arbres de décision.
Robuste au surapprentissage grâce à l'agrégation des prédictions de multiples arbres.	Peut être sensible au bruit dans les données.
Peut être utilisé pour la classification et la régression.	Requiert plus de ressources de calcul et de mémoire pour construire et évaluer de grands ensembles d'arbres.
Fournit une estimation de l'importance des caractéristiques pour l'analyse.	
Peut gérer des données manquantes sans nécessiter de prétraitement.	

## 2.5 Conclusion

Dans ce deuxième chapitre, nous avons étudié différentes méthodes de classification pour l'extraction des zones urbaines à partir d'images SAR. Nous avons exploré à la fois les approches supervisées et non supervisées, en mettant l'accent sur les méthodes de classification supervisées telles que SVM, MLP et Random Forest, ainsi que les méthodes de seuillage d'OTSU et K-means.

Les méthodes de classification supervisées se sont avérées efficaces pour extraire les zones urbaines en utilisant des ensembles d'apprentissage étiquetés. Elles ont permis de créer des modèles basés sur les caractéristiques extraites des images SAR, ce qui a permis de prédire la classe des pixels inconnus avec une bonne précision. Les SVM, MLP et Random Forest ont montré des performances prometteuses dans la classification des zones urbaines à partir d'images SAR.

D'autre part, les méthodes de seuillage d'OTSU et K-means, en tant que techniques de classification non supervisées, ont été utilisées pour la segmentation des images SAR en différents niveaux de gris. Ces méthodes ont permis de trouver des seuils optimaux pour diviser les pixels en classes représentant les zones urbaines et les arrière-plans. Elles offrent une approche simple et rapide pour l'extraction des zones urbaines sans nécessiter d'ensemble d'apprentissage préalable.



En combinant ces différentes méthodes de classification, nous avons pu obtenir des résultats encourageants dans l'extraction des zones urbaines à partir d'images SAR. Chaque méthode présente ses avantages et ses limitations, et le choix de la méthode dépend du contexte spécifique de l'application et des ressources disponibles.

# Chapitre 3

## Résultats et analyses

### 3.1 Introduction

Notre but est de détecter les zones urbaines, en utilisant des méthodes de détection basées sur la décomposition polarimétrique de Yamaguchi et Freeman, et la classification supervisée SVM, MLP, Random Forest. Afin de valider ces méthodes on a utilisé deux types d'images SAR sur deux régions différentes. La première image complètement polarimétrique de la ville de San Francisco acquise avec le satellite de télédétection RADARSAT2, et deux images bi-polarimétrique de la Baie d'Alger, acquises avec le satellite Sentinel-1 pour deux dates différentes afin de calculer la cohérence interférométrique. Ces deux régions présentent des caractéristiques urbaines distinctes et sont situées dans des contextes géographiques différents.

### 3.2 Présentation des données


- L'image de San Francisco est acquise dans la bande C, avec les quatre polarisations linéaires (HH, HV, VH et VV). La résolution de l'image obtenue est de 10 mètres en azimuth sur 5 mètres en radiale, ce qui signifie que chaque pixel de l'image représente une surface terrestre de  $10 \times 5$  mètres.
- Les images de baie d'Alger sont acquises aussi dans la bande C, avec deux polarisations linéaires (VH et VV). La résolution des images obtenues est de 22.5 mètres en azimuth sur 22.5 mètres en radiale, ce qui signifie que chaque pixel de l'image représente une surface terrestre de  $22.5 \times 22.5$  mètres

Images	Bande	Système d'acquisition	Polarisation	Dimension	Résolution	Date d'acquisition
Alger	C	Sentinel 1	VH et VV	1475 × 1795	22.5 × 22.5	19/11/2022
Alger	C	Sentinel 1	VH et VV	1475 × 1795	22.5 × 22.5	01/12/2022
San Francisco	C	Radarsat2	(HH, HV, VH et VV)	1726 × 1385	10 × 5	04/09/2008

TABLE 3.1 – Tableau des caractéristiques des images




(a) Image SAR RGB neuf bandes




(b) San Francisco optique


FIGURE 3.1 – La région d'étude de San Francisco



(a) Optique



(b) VV



(b) VH

FIGURE 3.2 – Baie d'Alger

### 3.3 Détection automatique des zones urbaines

Notre objectif principal est de détecter les zones urbaines. Pour commencer, nous avons utilisé la décomposition de Yamaguchi et Freeman pour analyser les images. Cependant, nous avons ensuite exploré une autre méthode de détection automatique en utilisant des données SAR qui ne sont pas entièrement polarimétriques. Dans notre cas, nous avons utilisé des images de la baie d'Alger en raison de la disponibilité des données fournies par Sentinel-1, qui sont accessibles gratuitement.

Nous avons appliqué la cohérence interférométrique, qui nécessite au moins deux dates d'observation pour calculer la cohérence. La cohérence nous fournit des informations sur

les zones urbaines, car celles-ci ne subissent généralement pas de changements importants sur de courtes périodes.

Cependant, si nous souhaitons étudier ou détecter les zones urbaines, nous pouvons choisir des dates d'observation plus éloignées, ce qui permet de détecter, par exemple, l'extension de ces zones, la construction de nouveaux bâtiments, l'éradication de bidonvilles, etc.

Ces applications dans les zones urbaines comprennent la planification urbaine, la détection des changements suite à des catastrophes naturelles telles que les séismes, où l'on peut identifier les zones urbaines ayant subi des dommages importants en les comparant avec des images précédentes. Ces informations peuvent être utilisées par les services de secours et la protection civile pour déployer des secours de manière plus efficace.

### 3.3.1 Décomposition polarimétrique d'images SAR





FIGURE 3.3 – Vérité terrain (ROI) de la région de SAN FRANCISCO

Classe	Couleur	Pixels
Eau	Blue	262654
Urbain	Rouge	247438
Végétation	Vert	32218

TABLE 3.2 – Les trois classes et leurs couleurs et leurs pixels

Pour mettre en œuvre les méthodes de détection et la manipulation des images, nous avons utilisé le langage de programmation Python, fortement recommandé dans la communauté scientifique et industrielle, et qui joue un rôle essentiel dans le domaine de l'intelligence artificielle. Toutes les opérations de manipulation des images SAR ont été effectuées en utilisant le langage de programmation Python.




(a) Freeman

(b) Yamaguchi

FIGURE 3.4 – *Résultat final*


Nous affichons les trois puissances des diffuseurs (double-rebond, volumique et surfacique) dans une image au format RGB. Dans cette représentation, la couleur rouge indique la diffusion en double-rebond, le vert représente la diffusion volumique et le bleu représente la diffusion surfacique. Les deux figure 3.4 illustre cette méthode, où l'on observe que les zones urbaines apparaissent en rose, qui est un mélange de rouge (double-rebond) et de bleu (surfacique). Cela implique qu'il y a deux types de diffuseurs dans les zones urbaines, à savoir le double-rebond et le surfacique. En revanche, l'océan est coloré en bleu, ce qui indique la présence d'un seul type de diffusion, à savoir la diffusion surfacique.

FIGURE 3.5 – *couleurs RGB*

La décomposition de Yamaguchi offre une représentation visuelle plus claire et intuitive des différentes composantes de diffusion en utilisant des canaux de couleurs distincts pour les puissances de diffusion. Cela facilite l'interprétation visuelle et la détection des zones

urbaines. En revanche, la décomposition de Freeman utilise une représentation basée sur les polarisations et nécessite une analyse plus approfondie pour extraire des informations sur les caractéristiques urbaines.

Afin de réaliser une détection automatique des zones urbaines à base des décomposition polarimétriques on a effectué une condition sur les valeurs des puissances des diffusions canoniques. Tel que dans les zones urbaine la puissance double rebond est la plus dominante. Les résultats d'application de la détection automatique des zones urbaine sont indiqués dans les figures 3.6.



(a) Freeman

(b) Yamaguchi

FIGURE 3.6 – Résultat final après la condition

Lorsque nous avons appliqué une condition basée sur les valeurs de puissance des rétrodiffusions canoniques, nous avons observé que la puissance de double rebond était prédominante dans les zones urbaines. Une analyse comparative entre les méthodes de décomposition de Yamaguchi et de Freeman a révélé que la décomposition de Yamaguchi donnait de meilleurs résultats. En effet, les zones urbaines étaient représentées par des couleurs plus claires, généralement le blanc, tandis que les zones non urbaines étaient représentées par des couleurs plus sombres, généralement le noir, dans l'image résultante.

### 3.3.2 Le seuillage d'Otsu et de k-means

Pour détecter automatiquement les zones urbaines sur des images SAR non entièrement polarimétriques, telles que celles capturées par le satellite Sentinel-1, nous allons utiliser

la cohérence.

Les zones urbaines présentent une cohérence élevée par rapport aux autres régions de la surface terrestre, car elles ont tendance à conserver leur structure au fil du temps. Par conséquent, nous pouvons utiliser la cohérence pour distinguer les zones urbaines des autres types de terrain.

Nous pouvons effectuer un seuillage sur les valeurs de cohérence pour segmenter les zones urbaines. Le seuillage peut être réalisé manuellement en définissant un seuil basé sur une analyse visuelle des images. Alternativement, nous pouvons utiliser une méthode de seuillage automatique telle que la méthode d'Otsu.

La méthode d'Otsu est un algorithme de seuillage automatique largement utilisé. Elle calcule le seuil optimal en maximisant la variance interclasse entre les pixels des zones urbaines et les pixels des autres régions. Cela permet d'obtenir une segmentation précise et adaptée aux caractéristiques spécifiques de l'image.

En utilisant la cohérence et le seuillage, nous pouvons détecter automatiquement les zones urbaines dans les images SAR. Cela facilite l'analyse et la cartographie des zones urbaines, ainsi que l'application de ces informations à des domaines tels que la planification urbaine, la gestion des ressources et l'évaluation environnementale.

### 3.3.2.1 Le prétraitement des données

Nous avons téléchargé les images SAR à partir du site de Copernicus Open Access Hub pour notre projet. Ensuite, nous avons effectué un prétraitement approfondi des données à l'aide du logiciel SNAP pour maximiser la qualité des images et améliorer la précision de l'extraction des zones urbaines.

Pour obtenir ces images, vous devez suivre les étapes suivantes :

1. Accédez au site Copernicus Open Access Hub, comme illustré dans la Figure 3.7, pour télécharger les images. Les recherches sont effectuées en fonction du type d'images et de la région géographique.
2. Pour choisir la région à étudier, cliquez sur le bouton marqué en rouge (switch to the area). Ensuite, utilisez le curseur pour sélectionner la zone souhaitée, comme illustré dans la Figure 3.8.
3. Pour localiser les images qui nous intéressent, nous devons sélectionner certaines informations telles que la date, la polarisation, le satellite et le type de produit, comme illustré dans la Figure 3.9.

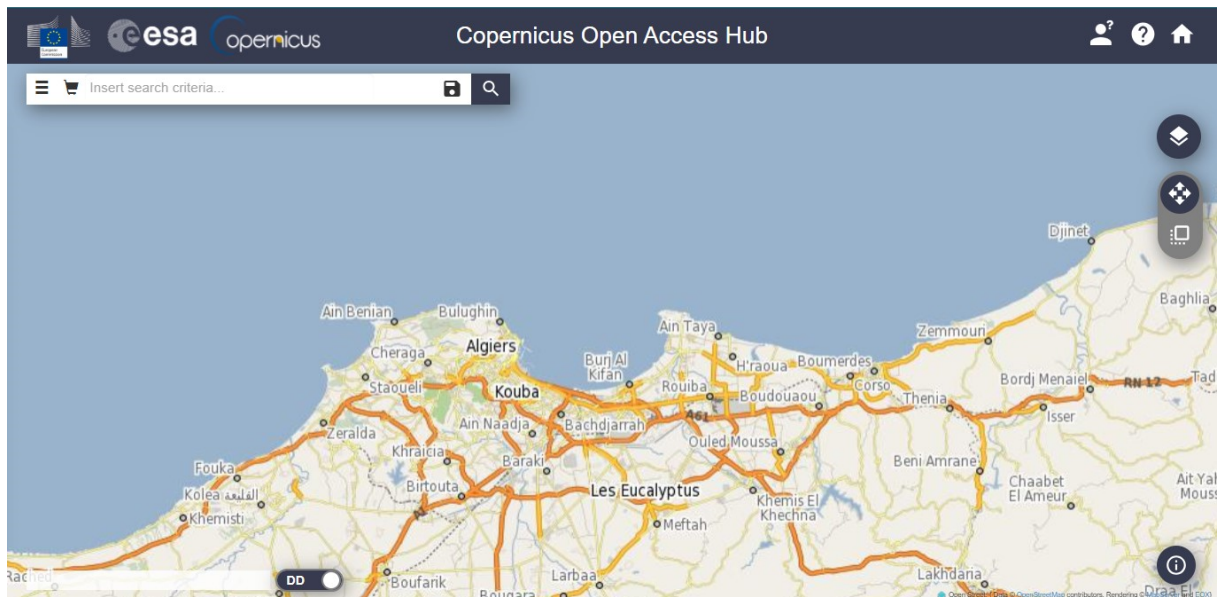


FIGURE 3.7 – Plateforme d'accès libre Copernicus Open Access Hub

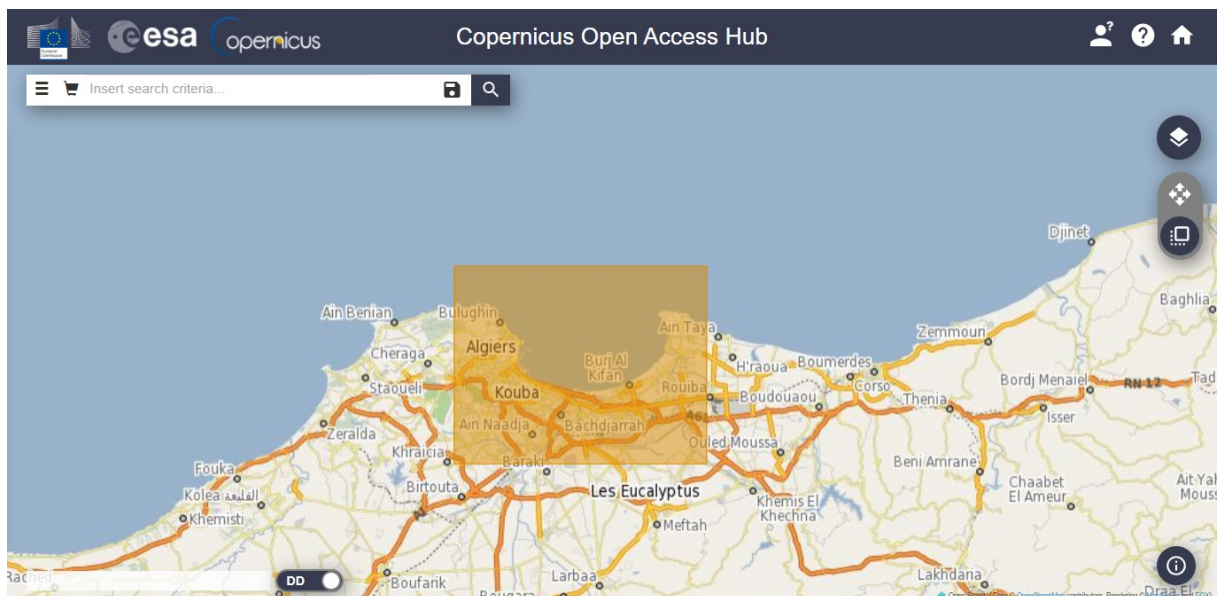


FIGURE 3.8 – Le choix de la région



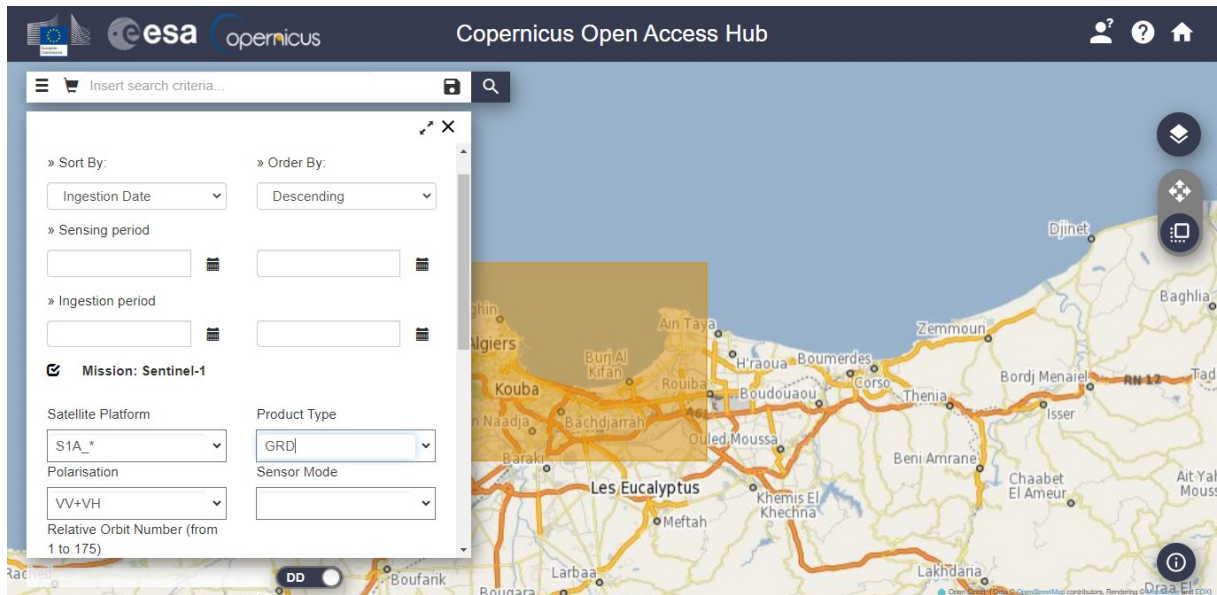


FIGURE 3.9 – Recherche avancée

4. Sélectionnez l'image à télécharger parmi les résultats. Vous obtiendrez une image de grande taille couvrant une vaste étendue de la côte algérienne (la taille de l'image de type de produit GRD (Ground Range Detected) et de mode capteur IW (Interferometric Wide swath) est de 4.09 Go).

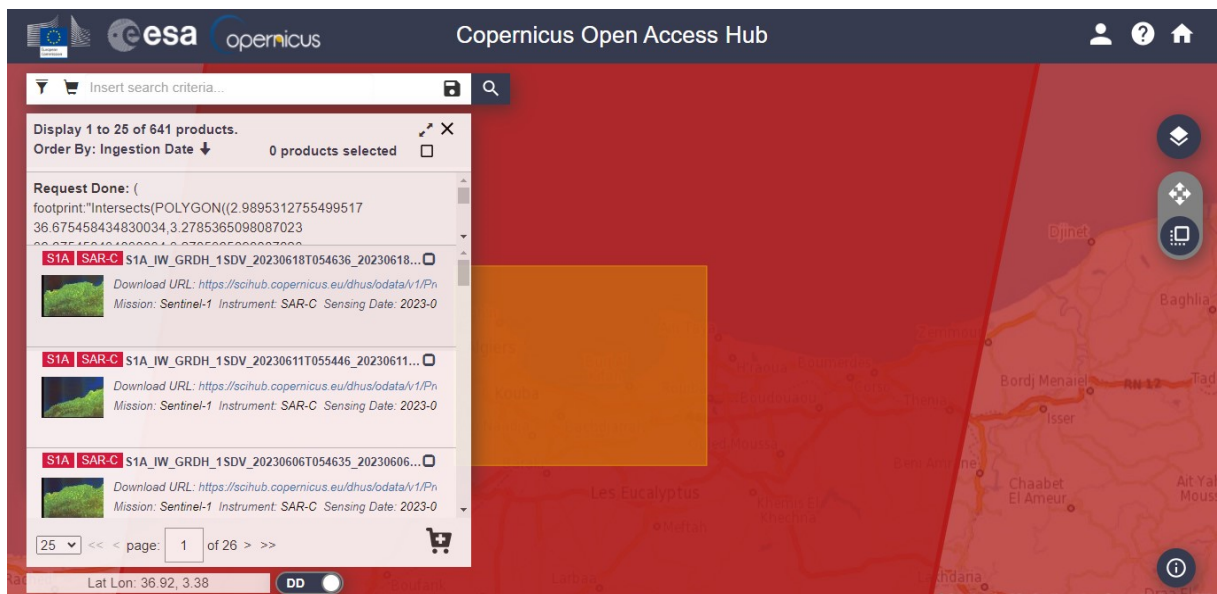


FIGURE 3.10 – Les résultats obtenus

On peut voir à partir du nom du fichier du logiciel SNAP que les dates d'acquisition, donc l'une a été acquise le 19 novembre 2022, l'autre le 01 décembre 2022. (figure 3.11)

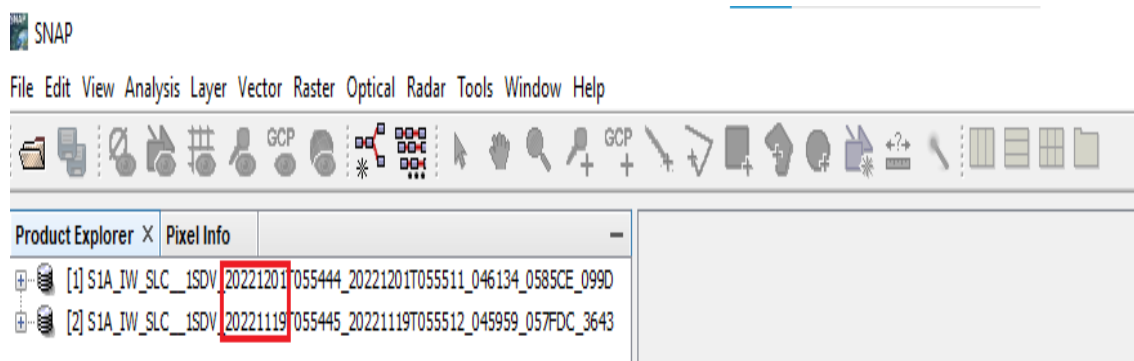


FIGURE 3.11 – Deux images avec deux dates différentes

Les images SAR fournies par le site Open Hub de Sentinel 1 sont sous format brut, afin de les exploiter dans les traitements de la télédétection on doit faire des prétraitements comme indiqué dans la figure 3.12. Et le résultat obtenu à chaque étape est indiqué dans la figure 3.13.

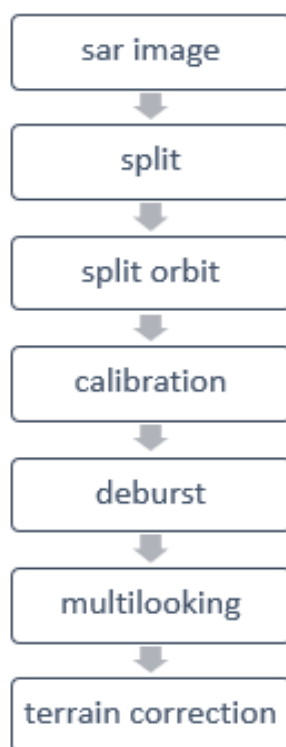
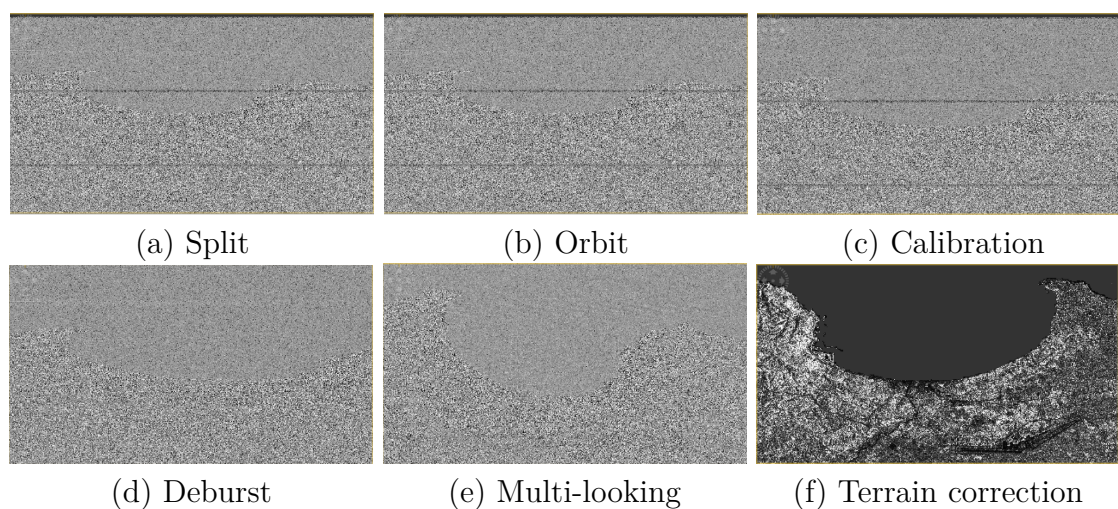



FIGURE 3.12 – Le prétraitement des données SAR avec SNAP

Nous allons donc répéter toutes ces étapes de prétraitement pour la deuxième image.

FIGURE 3.13 – *Étapes de traitement*FIGURE 3.14 – *La correction de terrain de la deuxième image*

Une fois que nous aurons fait cela, nous aurons calibré les deux images et corrigé le terrain. Ce que nous allons faire, c'est créer maintenant une autre image, qui est l'image de cohérence.

Les étapes suivies pour le calcul des paramètres de la cohérence dans le logiciel SNAP sont indiquées par l'organigramme illustré à la figure 3.15, et les résultats de chaque étape sont indiqués à la figure 3.16.

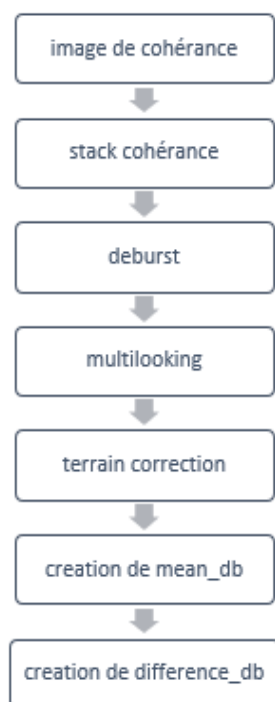


FIGURE 3.15 – Organigramme des étapes de calcul des paramètres de la cohérence

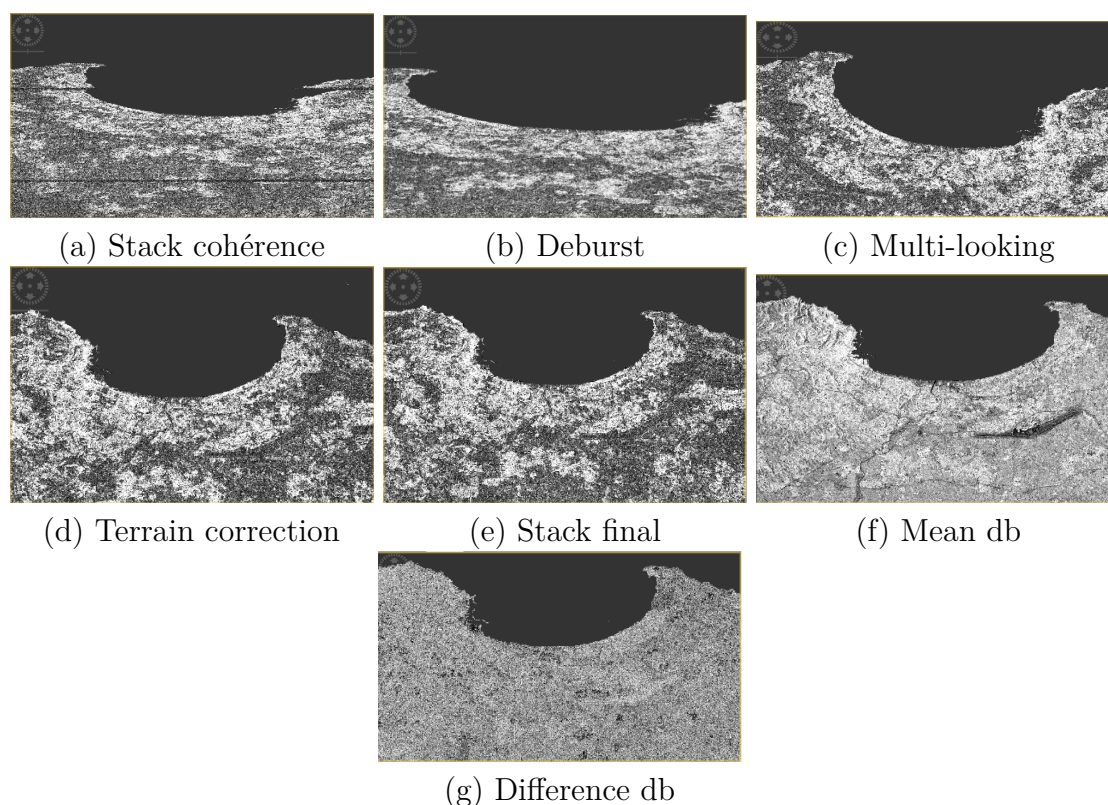


FIGURE 3.16 – Étapes de calcul des paramètres de la cohérence

Maintenant, nous disposons de ces nouvelles bandes et nous allons les utiliser pour créer un composite RGB. Pour ce faire, nous allons ouvrir un composite en utilisant ces nou-

velles bandes et sélectionner les trois canaux RGB correspondants. Plus précisément, nous utiliserons l'image de cohérence pour le canal rouge, l'image  $mean_{db}$  pour le canal vert, et l'image de différence dB pour le canal bleu. Ainsi, nous pourrions visualiser les différentes caractéristiques des images dans un seul composite RGB.





FIGURE 3.17 – les différentes caractéristiques des images dans un seul composite RGB


Les zones qui apparaissent en rouge dans l'image ont une rétrodiffusion faible et une cohérence élevée, ce qui suggère qu'elles pourraient être des zones agricoles ou des zones de sol nu. En revanche, les zones qui apparaissent en jaune présentent une rétrodiffusion élevée et une cohérence importante, ce qui suggère qu'elles pourraient correspondre à des zones urbaines.

Nous avons la possibilité de choisir une nouvelle bande que nous appellerons "empreinte urbaine" (urban footprint). À partir de cette bande, nous allons créer une nouvelle expression en utilisant une expression conditionnelle. Cette expression conditionnelle sera composée d'opérateurs et nous permettra de définir des seuils pour masquer les zones urbaines.

Pour ce faire, nous commencerons par sélectionner la rétrodiffusion moyenne. Nous appliquerons la condition suivante : "si" la rétrodiffusion  $mean_{db}$  est supérieure à  $-11.03$  "et" la cohérence est supérieure à  $0,59$ . Si cette condition est remplie, le masque sera égal à 1 ; sinon, il sera égal à 0.



(a) Histogramme de la cohérence



(b) Histogramme de Mean db

FIGURE 3.18 – Histogramme de la cohérence et de Mean db

En utilisant cette expression conditionnelle, nous serons en mesure de masquer efficacement les zones urbaines et de les distinguer des autres types de terrain. Cela nous permettra d'obtenir une carte précise des empreintes urbaines dans notre analyse.




FIGURE 3.19 – *L'urbain footprint de l'image*

Dans notre démarche, nous allons procéder à un masquage des zones jaunes, qui sont supposées correspondre aux zones urbaines. Pour ce faire, nous allons effectuer une comparaison entre l'image masquée et l'image RGB. Il est important de veiller à ce que le curseur et le zoom soient synchronisés afin de pouvoir comparer les deux images simultanément. Une autre méthode de comparaison consiste à superposer les deux images pour les visualiser conjointement et analyser les correspondances ou les divergences entre elles. Cette approche nous permettra d'examiner de manière plus approfondie les zones urbaines identifiées et de les comparer avec l'image RGB, facilitant ainsi notre compréhension des caractéristiques spécifiques des zones urbaines détectées.

Une autre approche possible pour la détection des zones urbaines est l'utilisation de l'algorithme de regroupement k-means. Cependant, cette méthode nécessite une connaissance préalable ou des informations sur le nombre de classes à détecter. Il convient de noter que cette méthode n'est pas entièrement automatique, car elle ne fournit pas directement les classes souhaitées. Il est de notre responsabilité de définir et de séparer les différentes classes après l'application de l'algorithme. Cela nécessite une analyse et une interprétation supplémentaires pour identifier et étiqueter correctement les zones urbaines détectées par l'algorithme de regroupement k-means.




FIGURE 3.20 – Superposition des deux image urban footprint et composite RGB






FIGURE 3.21 – Application de *k-means* sur l'image SAR

### 3.4 Classification supervisée de la surface terrestre

Dans la classification supervisée avec des méthodes telles que SVM (Support Vector Machine), MLP (Multilayer Perceptron) et RF (Random Forest), nous utilisons deux jeux de données : Radarsat-2 et Sentinel-1. Le jeu de données Radarsat-2 fournit des informations supplémentaires, cependant, les deux jeux de données ne sont pas comparés directement entre eux dans le processus de classification. Au lieu de cela, chaque jeu de données est utilisé séparément pour entraîner le modèle de classification, en utilisant des exemples étiquetés pour chaque classe d'intérêt. Les caractéristiques extraites des images Radarsat-2 et Sentinel-1 sont utilisées comme entrées pour les modèles de classification, permettant ainsi d'obtenir une classification précise des zones d'intérêt dans chaque jeu de données.



(a) ROI de la région de SAN FRANCISCO (1726 x 1385)




(b) 25% de ROI de SAN FRANCISCO

FIGURE 3.22 – *Region Of Interest de San Francisco*

Supposons que nous avons un ensemble de données contenant 100 échantillons. Dans notre approche, nous avons divisé cet ensemble en utilisant une répartition de 75% pour les tests et de 25% pour l'entraînement. Cela signifie que nous avons utilisé 75 échantillons pour tester et évaluer les performances de notre modèle, tandis que les 25 échantillons restants ont été utilisés pour l'entraînement, c'est-à-dire pour apprendre les paramètres du modèle.





(a) SVM

(b) Random Forest

(c) MLP

FIGURE 3.23 – Classification "San Francisco"




FIGURE 3.24 – Matrices de confusion "San Francisco"

	urbain	eau	végétation
SVM	91.8612	97.8492	99.8612
MLP	92.1267	96.0168	99.9457
RF	91.8167	97.8492	99.5612

TABLE 3.3 – La précision globale des classifieurs par rapport au classes

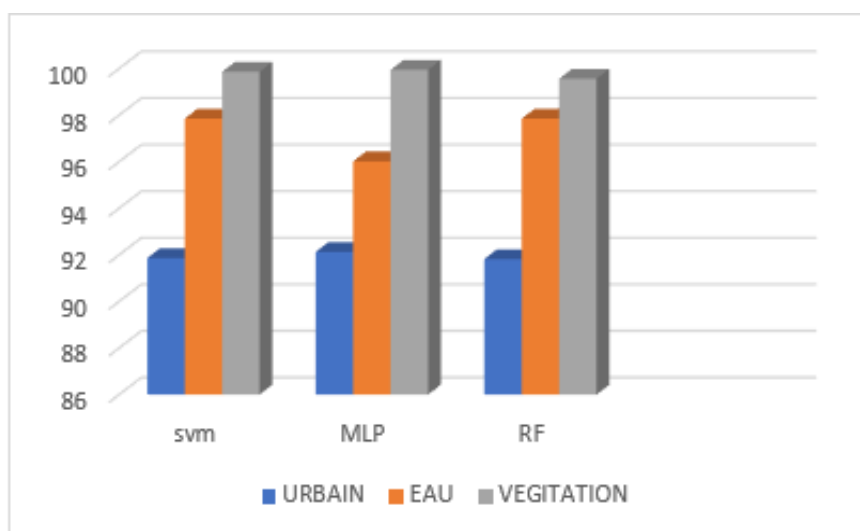


FIGURE 3.25 – Histogramme 3D représente la précision globale de chaque type de classification

	SVM	MLP	RP
urbain	91.8612	92.1267	91.8167
eau	97.8492	96.0168	97.8492
Végétation	99.8612	99.9457	99.5612

TABLE 3.4 – La précision globale des classifieurs par rapport au classes






FIGURE 3.26 – Histogramme groupé représente la précision globale de chque type de classification



(a) ROI de la région de la Baie d'Alger(1475 x 1795)




(b) 25% de ROI de la baie d'Alger


FIGURE 3.27 – Region Of Interest de San Francisco

Classe	Couleur	Pixels
Eau	Blue	4842
Urbain	Rouge	37871
Végétation	Vert	25483


TABLE 3.5 – Les trois classes et leurs couleurs et leurs pixels




(a) SVM



(b) MLP



(c) Random Forest avec les paramètres par défaut



(d) RF avec 400 arbres et trois "leaf" et trois "split"

FIGURE 3.28 – Classification "Baie d'Alger"

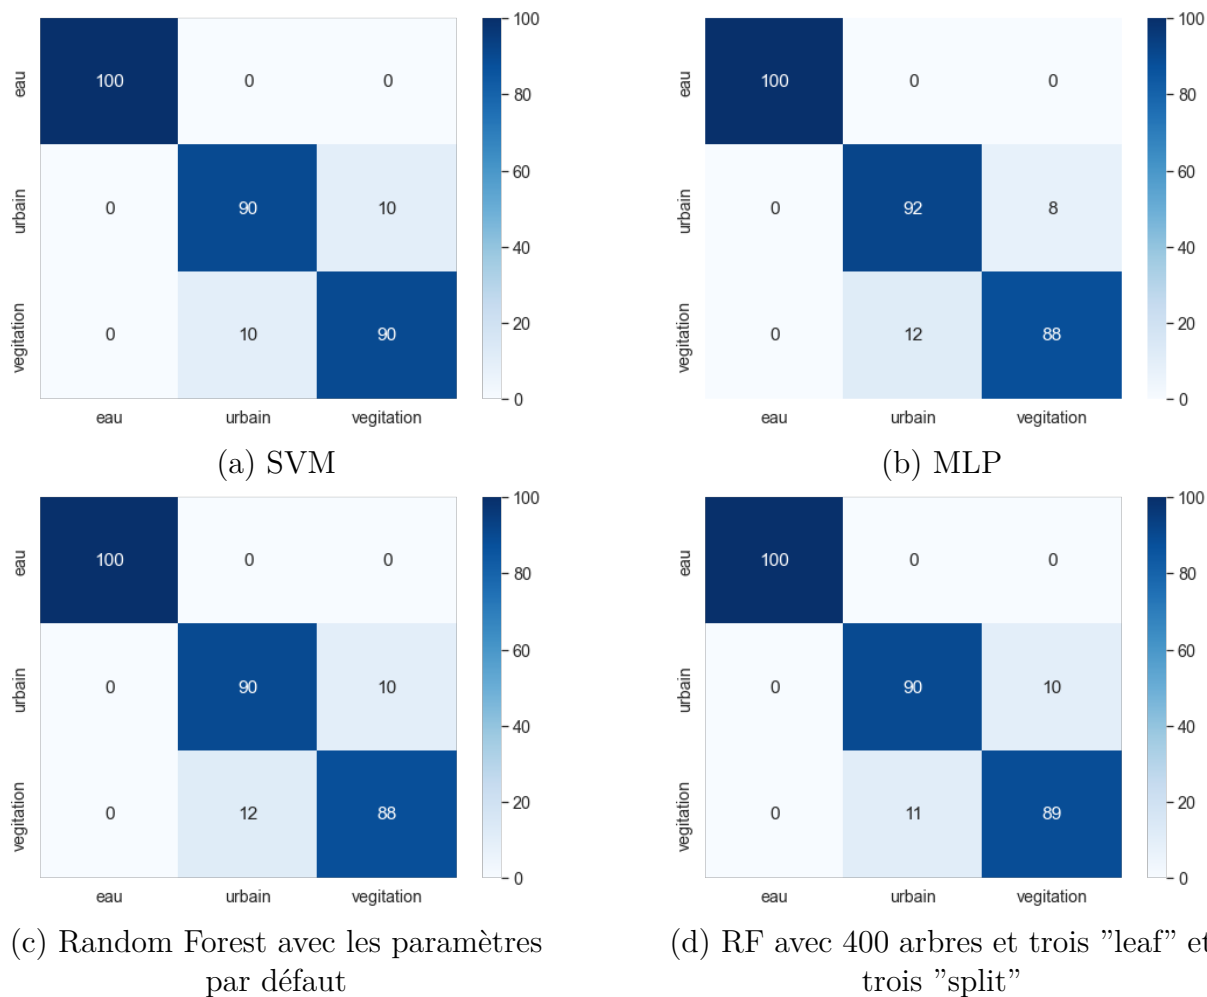


FIGURE 3.29 – Matrice de confusion "Baie d'Alger"

	urbain	eau	végétation
SVM	91.8612	97.8492	99.8612
MLP	92.1267	96.0168	99.9457
RF	91.8167	97.8492	99.5612

TABLE 3.6 – La précision globale

	Kappa accuracy de sanfrancisco	Kappa accuracy de baie d'alger
Svm	98.1484	83.6918
Mlp	97.3868	83.4199
Rf1	98.1484	81.7099
Rf2	99.0657	83.0665

TABLE 3.7 – La précision Kappa de San Francisco et de la baie d'Alger

Nous avons constaté une tendance intéressante lors de notre analyse comparative des différents algorithmes. En particulier, nous avons observé que le coefficient kappa et l'exactitude (accuracy) obtenus avec la méthode SVM dans la région de la baie d'Alger étaient

nettement plus élevés que ceux des autres algorithmes évalués ; concernant la région de San Francisco nous avons remarqué que RF avec le paramètre de 400 arbres nous a donné la meilleur précision (99.0657% de précision). Ces résultats indiquent clairement que SVM et RF présentent une performance supérieure pour la détection des zones urbaines dans notre étude. Ces observations renforcent notre confiance dans l'efficacité de SVM et RF en tant qu'algorithmes de choix pour cette tâche spécifique.

Nous constatons que les résultats obtenu sur l'image de San Francisco sont plus fiable que celle obtenu sur la baie d'Alger et cela grâce à la bonne résolution donnée par le satellite RADARSAT-2

#### Note :

- La kappa accuracy est une mesure statistique utilisée pour évaluer la performance d'un modèle de classification en tenant compte de l'accord entre les prédictions du modèle et les étiquettes réelles des échantillons. Elle prend en compte la concordance qui est due au hasard et évalue ainsi la précision du modèle corrigée par cette concordance aléatoire. Une valeur de kappa proche de 1 indique une bonne concordance entre les prédictions du modèle et les étiquettes réelles, tandis qu'une valeur proche de 0 indique une concordance similaire à celle due au hasard.
- La matrice de confusion est un outil utilisé pour évaluer les performances d'un modèle de classification. Elle permet de comparer les prédictions du modèle aux vraies étiquettes des échantillons et de calculer le nombre de vrais positifs, de faux positifs, de vrais négatifs et de faux négatifs. Cette matrice est essentielle pour calculer différentes mesures d'évaluation telles que la précision, le rappel, le taux de faux positifs, etc.
- Concernant la méthode de classification MLP, nous avons utilisé les paramètres suivants :
  - 500 couches cachées
  - La fonction d'activation ReLU

## 3.5 Conclusion

Notre projet vise à mener une étude approfondie sur les images SAR (Synthetic Aperture Radar) afin d'effectuer une classification supervisée et une extraction automatique des régions urbaines et des différentes classes de la surface terrestre. Pour cela, nous avons mis en œuvre des méthodes de classification supervisée, ainsi que d'autres méthodes non supervisées. Les résultats obtenus ont démontré de bonnes performances, avec un taux de classification global supérieur à 80% pour toutes les méthodes. En ce qui concerne la détection des zones urbaines, nous avons obtenu un taux de réussite supérieur à 90%.

---

Nous sommes parvenus à atteindre l'objectif principal de notre projet de recherche. Cependant, il convient de souligner que le domaine de la télédétection offre encore de nombreuses possibilités d'amélioration et de perspectives futures. Nous suggérons notamment d'explorer la fusion des méthodes de classification pour obtenir des résultats encore plus précis et de se pencher sur les méthodes d'apprentissage profond, qui offrent des opportunités prometteuses. En conclusion, notre projet a ouvert de nouvelles perspectives dans ce domaine et a suscité un fort intérêt pour des développements ultérieurs.

# Conclusion Générale

EN conclusion, ce mémoire a exploré l'extraction des zones urbaines à partir d'images SAR en utilisant diverses techniques et méthodes d'analyse. Nous avons étudié en détail les principes de formation d'images SAR, ainsi que l'importance de la polarimétrie et des décompositions polarimétriques pour caractériser les zones urbaines. Nous avons également examiné les méthodes de classification supervisées telles que SVM, MLP et Random Forest, ainsi que les méthodes de seuillage non supervisées telles que OTSU et K-means.

L'application de ces méthodes sur des images de San Francisco et de la baie d'Alger a permis d'obtenir des résultats significatifs. Nous avons constaté que la méthode de classification SVM avec une sélection minutieuse des régions d'apprentissage a donné les meilleurs résultats pour l'extraction des zones urbaines. Cela ouvre des perspectives prometteuses pour la cartographie et la surveillance des zones urbaines à partir de données SAR, avec des applications potentielles en planification urbaine et en gestion des ressources.

Cependant, il convient de souligner que ce domaine de recherche est en constante évolution, et il reste des défis à relever. L'amélioration des algorithmes de classification, l'exploration de nouvelles techniques d'analyse d'images SAR, ainsi que l'intégration de données multisources pour une meilleure caractérisation des zones urbaines sont autant de pistes à explorer pour des travaux futurs.

Enfin, ce mémoire nous a permis de mieux appréhender les enjeux liés à l'exploitation des images SAR pour l'extraction des zones urbaines. Cela nous a également sensibilisés à l'importance de la télédétection dans la compréhension et la gestion des environnements urbains. Nous espérons que nos travaux contribueront à la poursuite des recherches dans ce domaine passionnant et ouvriront de nouvelles perspectives pour l'utilisation des données SAR dans la planification et la gestion des zones urbaines.

# Bibliographie

- [1] P. Formont, *Outils statistiques et géométriques pour la classification des images SAR polarimétriques hautement texturées*. PhD thesis, Rennes 1, 2013.
- [2] A. Moreira, P. Prats-Iraola, M. Younis, G. Krieger, I. Hajnsek, and K. P. Papathanassiou, “A tutorial on synthetic aperture radar,” *IEEE Geoscience and remote sensing magazine*, vol. 1, no. 1, pp. 6–43, 2013.
- [3] J. A. Richards *et al.*, *Remote sensing with imaging radar*, vol. 1. Springer, 2009.
- [4] B. Souissi, *Caractérisation de l’état de surface et optimisation de la cohérence interférométrique par utilisation de la polarimétrie radar*. PhD thesis, Alger, 2005.
- [5] Y. Yamaguchi, A. Sato, W.-M. Boerner, R. Sato, and H. Yamada, “Four-component scattering power decomposition with rotation of coherency matrix,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 49, no. 6, pp. 2251–2258, 2011.
- [6] C. M. Bishop, “Information science and statistics,” *Pattern recognition and machine learning*. Springer, 2006.
- [7] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. MIT press, 2016.
- [8] H. Cruz, M. Véstias, J. Monteiro, H. Neto, and R. P. Duarte, “A review of synthetic-aperture radar image formation algorithms and implementations : A computational perspective,” *Remote Sensing*, vol. 14, no. 5, p. 1258, 2022.
- [9] J.-S. Lee and E. Pottier, *Polarimetric radar imaging : from basics to applications*. CRC press, 2017.
- [10] J. D. Ballester-Berman and J. M. Lopez-Sanchez, “Applying the freeman–durden decomposition concept to polarimetric sar interferometry,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 48, no. 1, pp. 466–479, 2009.
- [11] D. Liu and J. Yu, “Otsu method and k-means,” in *2009 Ninth International conference on hybrid intelligent systems*, vol. 1, pp. 344–349, IEEE, 2009.
- [12] Z. Y. Tan, S. N. Basah, H. Yazid, and M. J. A. Safar, “Performance analysis of otsu thresholding for sign language segmentation,” *Multimedia Tools and Applications*, vol. 80, pp. 21499–21520, 2021.
- [13] J. Cervantes, F. Garcia-Lamont, L. Rodríguez-Mazahua, and A. Lopez, “A comprehensive survey on support vector machine classification : Applications, challenges and trends,” *Neurocomputing*, vol. 408, pp. 189–215, 2020.
- [14] A. Parmar, R. Katariya, and V. Patel, “A review on random forest : An ensemble classifier,” in *International conference on intelligent data communication technologies and internet of things (ICICI) 2018*, pp. 758–763, Springer, 2019.