

THÈSE

En vue de l'obtention du Diplôme de Doctorat en Sciences

Présenté par : Mme. ABIDI Meriem

Intitulé

**L'exploitation des méta-heuristiques pour le traitement multi-sources
des images satellitaires, Application: étude des changements d'occupation des sols.**

Faculté : des Mathématiques et Informatique

Département : Informatique

Spécialité : Informatique

Option : Informatique

Devant le Jury Composé de :

<i>Membres de Jury</i>	<i>Grade</i>	<i>Qualité</i>	<i>Domiciliation</i>
<i>Mr. BELMADANI Abderrahim</i>	<i>Professeur</i>	<i>Président</i>	<i>USTO-MB</i>
<i>Mme FIZAZI Hadria</i>	<i>Professeur</i>	<i>Encadrant</i>	<i>USTO-MB</i>
<i>Mme. CHOURAQUI Samira</i>	<i>Professeur</i>		<i>USTO-MB</i>
<i>Mr. SI MOHAMED MOHAMMED Arezki</i>	<i>Directeur de recherche</i>	<i>Examineurs</i>	<i>CDS</i>
<i>Mr. MAHI Habib</i>	<i>Maitre de recherche</i>		<i>CTS</i>
<i>Mr. KAROUI Moussa Sofiane</i>	<i>Directeur de recherche</i>		<i>CTS</i>

Remerciements

Je remercie **Dieu** tout puissant de m'avoir donné le courage et la patience pour bien mener ce travail.

Tout d'abord, Je voudrais remercier ma directrice de thèse Madame **FIZAZI Hadria** professeur à l'Université des Sciences et de la Technologie d'Oran, pour sa disponibilité qu'elle m'a octroyée et la confiance qu'elle m'a accordée, ses conseils ainsi que son optimisme. Je lui exprime ma plus vive gratitude.

Mes remerciements s'adressent également à **Mr. BELMADANI Abderahim** Professeur à l'université de l'USTO - MB qui m'a fait l'honneur de présider le jury. Je remercie également **Mme. CHOURAQUI Samira** Professeur à l'université de l'USTO – MB, **Mr.SI MOHAMED MOHAMMED Arezki** Directeur de recherche au Centre de Développement des Satellites (CDS), **Mr. MAHI Habib** Directeur de recherche au Centre des Techniques Spatial (CTS), **Mr. KAROUI Moussa Sofiane** Directeur de recherche au Centre des Techniques Spatial (CTS) qui ont accepté de juger ce travail. Qu'ils trouvent ici de ma plus haute considération.

Je tiens remercier l'ensemble du personnel administratif et pédagogique de la faculté mathématiques et informatique.

Enfin, je remercie toute personne ayant contribué de près ou de loin à la réalisation de ce travail.

Dédicace

Je dédie cette thèse à mes parents qui m'ont guidée et transmis les valeurs précieuses de la vie.

A mes frères Abdelkader et Mohamed Hamed et mes sœur Assia et ses fils, Raihana, Mays avec qui j'ai passé les plus beaux moments de mon enfance.

A la famille ABIDI et la famille BOUDALI.

A la mémoire de mon beau père Rachid allah yarhmah .

A mon marie Nourredine qui ma soutenue et aidée et mon fils Mohamed Nadir.

A Mazouzi halima et Hanchour Hasnia qui m'ont aidé et soutenue.

A tous mes proches collaborateurs qui ont fourni un grand effort pour l'élaboration de cette these.

Liste des Figures

Liste des figures

Chapitre 01

Figure 1.1: Les étapes principales de la télédétection	6
Figure 1.2 : Image numérique extraite d'une image satellitaire.....	9
Figure 1.3 : l'image (a) représente un extrait d'une image de réflectance SPOT/HRV de la plaine du Danube en Juin 2001. Les images (b) et (c) représentent des images du même site simulé par moyen nage par blocs respectivement de taille 16×16(moyenne résolution) et de taille 50×50 (basse résolution)	10
Figure 1.4 : Représentation de la matrice de confusion	17
Figure 1.5 : Présentation schématique d'un MLP.....	18
Figure 1.6 : Les processus de la détection des changements.....	22

Chapitre 02

Figure 2.1: Différence entre un optimum global et des optima locaux	27
Figure 2.2: Classification des méthodes d'optimisation	28
Figure 2.3 : l'algorithme du recuit simulé.....	33
Figure 2.4 : L'algorithme de PSO	36
Figure 2.5 : Illustration de la capacité des fourmis à chercher de la nourriture en minimisant leur parcours.....	37
Figure 2.6 : L'algorithme d'ACO	38
Figure 2.7 : L'algorithme de GSA	41
Figure 2.8 : L'algorithme d'AIS	42

Liste des figures

Chapitre 03

Figure 3.1 : MLP avec une structure 2-3-1.	46
Figure 3.2 : Hybridation du MLP et les algorithmes méta heuristiques	49
Figure 3.3 : Organigramme du modèle MLP/PSO.....	51
Figure 3.4 : Étapes générales de l'algorithme de recherche gravitationnelle	54
Figure 3.5 : Étapes de l'algorithme PSO GSA.....	57
Figure 3.6 : Exemple de détection de changement.....	58
Figure 3.7 : Schéma du processus adopté.....	67

Chapitre 04

Figure 4.1 : Les images satellitaires de site d'étude.....	71
Figure 4.2 : Images satellitaires selon les trois canaux RGB (4, 3, 2).	73
Figure 4.3 : Image échantillonnée.	74
Figure 4.4 : Classification MLP/PSO avec la taille de population =50	78
Figure 4.5: Classification MLP/GSA avec la taille de population=50.....	81
Figure 4.6: Classification MLP/PSOGSA avec la taille de population=50.	84
Figure 4.7 : Précisions globales relatives aux différentes expérimentations.....	86
Figure 4.8 : Classification par MLP/PSOGSA.....	87
Figure 4.9: Classification par MLP/PSO.....	88
Figure 4.10: Classification par MLP/GSA	88
Figure 4.11: Histogramme représentant les précisions globales obtenues par les classifieurs.	90
Figure 4.12: Histogramme représentant EQM obtenues par les classifieurs.	91

Liste des figures

Figure 4.13 : Schéma générale de l'approche proposée.....	92
Figure 4.14 : Localisation de la zone touchées par les feux de forêts.....	93
Figure 4.15: L'image satellitaire d'Oran 29/06/2020.....	94
Figure 4.16 : L'image satellitaire d'Oran 31/07/2020.....	94
Figure 4.17: Indice de végétation NDVI appliqué sur l'image 29/06/2020.....	96
Figure 4.18 : Indice de végétation NDVI appliqué sur l'image 31/07/2020.....	96
Figure 4.19 : Classification d'image LANDSAT-8 de 29/06/2020	97
Figure 4.20 : Classification d'image LANDSAT 8 de 31/07/2020.....	99
Figure 4.21 : Carte des changements.	100

Liste des Tableaux

Listes des Tableaux

Chapitre 01

Tableau 1.1 : Etude détaillée des travaux sur la détection des changements.....	23
---------------------------------------------------------------------------------	----

Chapitre 03

Tableau 3.1 : Techniques de détection de changement	60
-----------------------------------------------------------	----

Chapitre 04

Tableau 4.1 : Caractéristiques des données utilisées (Figure 4.1.a)	72
---------------------------------------------------------------------------	----

Tableau 4.2 : Précisions globales obtenues par le classifieur MLP/PSO en variant de la taille de population.....	77
------------------------------------------------------------------------------------------------------------------	----

Tableau 4.3: EQM obtenues par le classifieur MLP/PSO en variant de la taille de population.	77
--------------------------------------------------------------------------------------------------	----

Tableau 4.4 : Matrice de confusion relative à la classification MLP/PSO	78
-------------------------------------------------------------------------------	----

Tableau 4.5 : Précisions globales obtenues par le classifieur MLP/GSA en variant la taille de population.....	80
---------------------------------------------------------------------------------------------------------------	----

Tableau 4.6 : EQM obtenues par le classifieur MLP/GSA en variant la taille de population.	80
------------------------------------------------------------------------------------------------	----

Tableau 4.7 : Matrice de confusion relative à la classification MLP/GSA	81
-------------------------------------------------------------------------------	----

Tableau 4.8 : Précisions globales obtenues par le classifieur MLP/PSOGSA en variant la taille de population.....	83
------------------------------------------------------------------------------------------------------------------	----

Tableau 4.9 : EQM obtenues par le classifieur MLP/PSOGSA en variant la taille de population.	83
---------------------------------------------------------------------------------------------------	----

Tableau 4.10 :Matrice de confusion relative à la classification MLP/PSOGSA	84
----------------------------------------------------------------------------------	----

Tableau 4.11: Précisions globales obtenues par les trois classifieurs en variant le nombre de neurone de la couche cachée	85
---------------------------------------------------------------------------------------------------------------------------------	----

Listes des Tableaux

Tableau 4.12 : EQM obtenues par les trois classifieurs en variant le nombre de neurone de la couche cachée.....	86
Tableau 4. 13: Matrice de confusion relative à la classification par MLP/PSOGSA.....	87
Tableau 4.14 : Comparaison des précisions globales, EQM et le temps d'exécutions des classifieurs	89
Tableau 4. 15: Caractéristiques des images Landsat utilisées	93
Tableau 4. 16: Pourcentages des classifications MLP/PSOGSA pour les deux images.....	97
Tableau 4.17 : Matrice de confusion relative à la classification d'image de 26/30/2020.	98
Tableau 4.18 : Matrice de confusion relative à la classification d'image de 31/07/2020.	99
Tableau 4.19 : Superficie de changement entre 29-06-2020 et 31-07-2020.....	101

Table des matières

Remerciements.....	i
Résumé.....	ii
Introduction générale.....	1
Chapitre 01 : Généralité sur la télédétection	
I.1 Introduction	4
I.2 Définition de la télédétection	4
I.3 Les principales étapes de la télédétection.....	4
I.4 L'équipement de télédétection	6
I.4.1 Les plates formes	6
I.4.1.1 Les satellites.....	6
I.4.1.2 Les capteurs	7
I.5 Télédétection passive et télédétection active.....	7
I.6 Domaines d'application de la télédétection.....	8
I.7 L'image satellitaire.....	8
I.7.1 Résolution d'image satellite	9
I.7.1.1 Résolution spatiale.....	9
I.7.1.2 Résolution spectrale.....	10
I.7.1.3 Résolution temporelle	11
I.7.1.4 Résolution radiométrique.....	11
I.8 Types d'images satellitaires	12
I.9 Traitement des images satellitaires.....	13
I.9.1 classification	15

Table des matières

I.9.1.1 Les méthodes de classification	15
1.9.1.2 Classification par réseaux de neurones multicouches (MLP)	17
1.9.2 La détection des changements	19
I.9.2.1 Changements d'occupation des sols	20
I.10 Conclusion.....	24

Chapitre 02 : Les Métaheuristiques

2.1 Introduction.....	26
2.2 Problème d'optimisation.....	26
2.2.1 Classification des méthodes d'optimisation.....	28
2.2.2 Heuristiques et Métaheuristiques	30
2.2.3 Classification des métaheuristiques	31
2.2.3.1 Les métaheuristiques à solution unique	31
2.2.3.2 Les métaheuristiques à population de solutions.....	34
2.3 Conclusion	43

Chapitre 03 : Conception de l'approche proposée

3.1 Introduction.....	45
3.2 Réseaux de neurones MLP	45
3.2.1 Le fonctionnement du réseau MLP	45
3.2.2 L'apprentissage.....	47
3.2.3 Algorithme de rétro propagation du gradient.....	48
3.2.4 L'optimisation du réseau de neurones MLP	48

Table des matières

3.2.4.1 L'optimisation du réseau de neurones MLP par PSO.....	49
3.2.4.2 L'optimisation du réseau de neurones MLP par GSA	52
3.2.4.3 L'optimisation du réseau de neurones MLP par PSO GSA.....	55
3.3 La détection de changement	57
3.3.1 Méthodes de détection des changements	58
3.3.1.1 Méthodes algébriques.....	60
3.3.1.2 Méthodes de transformation.....	62
3.3.1.3 Méthodes de classification	63
3.3.1.4 Méthodes avancées.....	65
3.3.1.5 Approches de Systèmes d'Information Géographique (SIG)	65
3.3.1.6 Méthodes d'interprétation visuelle.....	66
3.4 Schéma général de l'approche proposée.....	66
3.5 Conclusion.....	68

Chapitre 04 : Implémentation et résultats

4.1 Introduction.....	70
4.2 Site d'étude	70
4.3 But de l'application	72
4.4 Données utilisées pour la classification	73
4.4.1 La coloration et l'amélioration.....	73
4.4.2 L'échantillonnage.....	74
4.4.3 L'apprentissage	74

Table des matières

4.4.4 Classification.....	75
4.4.4.1 Classification MLP/PSO	76
4.4.4.2 Classification MLP/ GSA	79
4.4.4.3 Classification MLP/ PSO GSA	82
4.4.4.4 Comparaison entre les trois algorithmes	85
4.4.4.5 Comparaison avec retro propagation du gradient	89
4.5 Détection de changements	91
4.5.1 Données utilisées.....	92
4.5.2 Résultats de la classification	96
4.6 Conclusion	101
Conclusion générale.....	103
Références bibliographiques.....	105

Introduction Générale

Introduction générale

Dans ces vingt dernières années, une évolution croissante du nombre d'études menées sur les animaux vivants en groupe ou en société et plus particulièrement les insectes sociaux. Ces études dans la théorie de l'auto-organisation ont inspiré un grand nombre des chercheurs pour développer une nouvelle approche appelé les métaheuristiques.

Les méta-heuristiques sont des algorithmes généraux d'optimisation applicables à une grande variété des problèmes. Elles sont apparues dans le but de résoudre au mieux des problèmes d'optimisation, elles sont généralement inspirées de la nature : de la biologie (Algorithme génétiques, système immunitaire, etc.), l'éthologie (essaim de particules, colonie de fourmis, Firefly etc.). L'application des méta-heuristiques en classification d'image a connu une évolution particulière ces dernières années grâce aux avancées technologiques en matière de calcul de machine. Actuellement, de nombreux systèmes d'interprétation et d'analyse d'images font appel à la classification d'images. En télédétection, les données à classer dans une image sont les pixels. Ces derniers peuvent être décrits par la couleur, appelée valeur radiométrique.

Dans cette thèse on s'intéresse aux Réseaux de Neurones Multicouches (MLP) pour la classification supervisée d'images satellitaires, qui sont souvent utilisés, et ceci est dû à leurs simplicités et leurs propriétés d'approximation universelle.

L'identification des paramètres du réseau de neurones, appelés poids de connexion et biais, sont souvent obtenue par l'utilisation de l'algorithme de rétropropagation, back propagation (BP), basé sur la méthode de la descente du gradient, dont l'objectif est la minimisation de l'erreur d'apprentissage. Cependant, la surface de l'erreur est souvent complexe et présente des caractéristiques peu satisfaisantes pour réaliser une descente du gradient ce qui crée des inconvénients, tels que: la lenteur de la convergence, la sensibilité aux minima locaux et la difficulté à régler les paramètres d'apprentissage.

Introduction générale

Plusieurs algorithmes ont été développées dans le but d'améliorer l'apprentissage de MLP.

Dans cette thèse, notre objectif est d'appliquer une nouvelle métaheuristique PSO-GSA (l'hybridation de l'optimisation par essaim de particules et l'algorithme de recherche gravitationnelle) dans l'apprentissage de réseau de neurone MLP afin d'utiliser leur résultat de classification dans la détection de changement.

La détection de changements en traitement d'images est un ensemble de problèmes regroupant des domaines aussi variés de la télédétection.

Afin de présenter notre travail, nous l'avons structuré en (04) chapitres :

Le premier chapitre présente une vue sur la télédétection et l'imagerie satellitaire. Nous décrivons les principes de base de la télédétection en faisant appel aux différents traitements pouvant être effectué sur ces images.

Le deuxième chapitre, nous illustrons les méthodes métaheuristicques adaptées au classification d'image satellitaires.

Le troisième chapitre qui sera réservé à la présentation de l'approche proposée dans cette thèse. Nous nous intéresserons à la classification supervisée par les méthodes MLP/PSO, MLP-GSA, MLP/PSO-GSA afin d'injecter les résultats de classification dans un processus de détection de changements.

Le quatrième chapitre sera dédié à l'étude expérimentale de l'approche proposée. Nous présentons les différents tests sur des images satellitaires en se basant sur l'algorithme PSO, GSA et PSO-GSA. Nous comparons leurs performances avec d'autre algorithmes, ensuite, nous appliquons les résultats obtenus à la détection de changements.

Enfin, dans la conclusion générale, nous récapitulerons nos contributions et proposons des perspectives sur la base des travaux effectués.

Chapitre 01 :

Généralité sur la télédétection

Chapitre 01 : Généralité sur la télédétection

1.1 Introduction

La télédétection a connu un essor considérable au cours du XX^e siècle et surtout avec le lancement du premier satellite artificiel sputnik en 1957. De nombreux pays ont développé leurs propres programmes de télédétection. Les satellites d'observation de la terre sont en orbite et fournissent en permanence des milliers d'images pour des diverses domaines d'applications tel que la détection du changement d'occupation de sol.

Dans ce chapitre, nous allons présenter un état de l'art sur la télédétection et le traitement des données liées à ce champ de recherche.

1.2 Définition de la télédétection

Traduit de l'anglais « remote sensing », Télé signifie « à distance » et détection veut dire « découvrir » ou « déceler ». Le néologisme « remote sensing » fait son apparition aux Etats-Unis dans les années soixante, lorsque des nouveaux capteurs viennent compléter la traditionnelle photographie aérienne. Le terme de télédétection a été introduit officiellement dans la langue française en 1973 et sa définition officielle est la suivante : « Ensemble des connaissances et techniques utilisées pour déterminer des caractéristiques physiques et biologiques d'objets par des mesures effectuées à distance, sans contact matériel avec ceux-ci »(Kergomard 1990).

1.3 Les principales étapes de la télédétection

- **Source d'énergie ou d'illumination (A) :**

À l'origine de tout processus de télédétection se trouve nécessairement une source d'énergie pour illuminer la cible.

Chapitre 01 : Généralité sur la télédétection

- **Rayonnement et atmosphère (B) :**

Durant son parcours entre la source d'énergie et la cible, le rayonnement interagit avec l'atmosphère. Une seconde interaction se produit lors du trajet entre la cible et le capteur.

- **Interaction avec la cible (C) :**

Une fois parvenue à la cible, l'énergie interagit avec la surface de celle-ci. La nature de cette interaction dépend des caractéristiques du rayonnement et des propriétés de la surface.

- **Enregistrement de l'énergie par le capteur (D) :**

Une fois l'énergie diffusée ou émise par la cible, elle doit être captée à distance (par un capteur qui n'est pas en contact avec la cible) pour être enfin enregistrée.

- **Transmission, réception et traitement (E) :**

L'énergie enregistrée par le capteur est transmise, souvent par des moyens électroniques, à une station de réception où l'information est transformée en images (numériques ou photographiques).

- **Interprétation et analyse (F) :**

Une interprétation visuelle et/ou numérique de l'image traitée est ensuite nécessaire pour extraire l'information que l'on désire obtenir sur la cible.

- **Application (G) :**

La dernière étape du processus consiste à utiliser l'information extraite de l'image pour mieux comprendre la cible, pour nous en faire découvrir de nouveaux aspects ou pour aider à résoudre un problème particulier.

Ces sept étapes couvrent le processus de la télédétection, du début à la fin (Initiation à la télédétection, 2013).

Chapitre 01 : Généralité sur la télédétection

Le schéma suivant représente ces étapes :

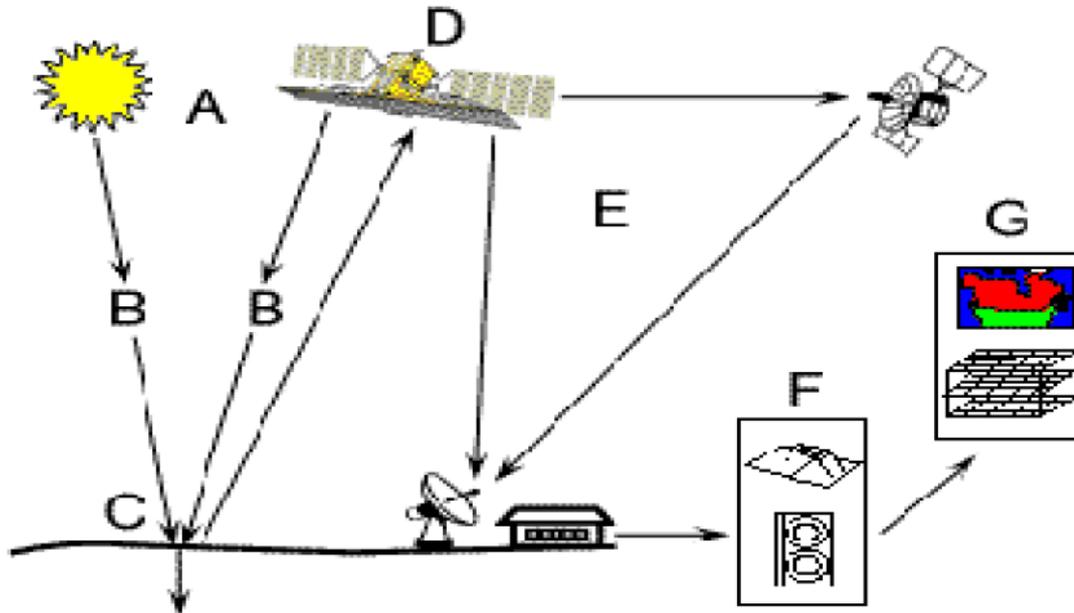


Figure 1.1: Les étapes principales de la télédétection

1.4 L'équipement de télédétection

1.4.1 Les plates formes

En télédétection, une plate-forme se définit comme étant tout objet mobile ou immobile qui peut contenir des instruments (capteurs) servant à enregistrer des informations spatiales et spectrales provenant d'objets divers.

Les plates-formes couramment utilisées en télédétection sont les satellites et les avions (Matese et al. 2015) (Mousselmel et al 2020).

1.4.1.1 Les satellites

Les satellites artificiels de la terre sont des plates-formes placées en orbite pour les besoins de la télédétection, des télécommunications et de la télémétrie (positionnement et navigation). Grâce à leur orbite, ces plates-formes spatiales permettent une couverture répétitive et continue de la surface de la terre (Campbell and Wynne 2011).

Chapitre 01 : Généralité sur la télédétection

1.4.1.2 Les capteurs

Le capteur suit une certaine trajectoire pour enregistrer le signal émis par la source d'énergie qui est réfléchié par la scène.

En général, les capteurs employés pour des fins de télédétection se subdivisent en deux catégories : les capteurs passifs et les capteurs actifs.

a) Les capteurs passifs

Les capteurs passifs sont techniquement développés afin de pouvoir détecter l'énergie naturelle réfléchié ou émise par un objet dans la partie du spectre électromagnétique qui va de l'ultra-violet jusqu'aux hyperfréquences passives (Fingas and Brown 2014).

b) Les capteurs actifs

Les capteurs actifs peuvent se définir comme étant des instruments qui émettent artificiellement de l'énergie sous forme d'impulsion à fréquence temporelle régulière et qui ont la capacité d'enregistrer le signal rétrodiffusé par les objets qui ont été en contact avec cette énergie (Gonenc et al 2019).

1.5 Télédétection passive versus télédétection active

La télédétection est dite passive lorsque la source illuminant la cible est indépendante du capteur. Généralement cette source est le soleil. C'est le cas des satellites SPOT (Satellite pour l'Observation de la Terre), LANDSAT (Land Satellite), METEOSAT (Meteorological Satellite), etc. La télédétection est dite active dans le cas contraire. C'est le cas du LIDAR (LIght Detection and Ranging) utilisant une source laser et le RADAR (RAdio Detection And Ranging) utilisant une source hyperfréquence. C'est l'exemple du satellite ERS-1 (European Remote Sensing Satellite) (Lang 2015).

Chapitre 01 : Généralité sur la télédétection

1.6 Domaines d'application de la télédétection

Le premier grand domaine d'application de la télédétection a été l'étude de l'atmosphère (météorologie et climatologie). L'intérêt de la télédétection dans ce domaine est d'assurer une couverture globale et très fréquemment répétée de la planète (Berghida et Mechtri 2017). Les capteurs utilisés permettent d'observer les nuages et leur déplacement, de mesurer des températures ou le contenu en vapeur d'eau de l'atmosphère. En océanographie, la télédétection offre l'avantage de permettre une vision synoptique de vastes régions qu'il est impossible d'obtenir par les moyens traditionnels (bateaux). Pour certaines études à petite échelle, les données des satellites météorologiques sont largement utilisées en océanographie (températures de surface de l'océan). Parmi les applications océanographiques, nous citons l'étude des glaces de mer en régions polaires (Houcine 2020).

Les applications terrestres de la télédétection sont extrêmement variées, et le champ des utilisations ne cesse de s'élargir : cartographie, géologie et prospection minière, mais aussi surveillance des cultures ou du couvert forestier, urbanisme, aménagement, génie civil, etc.... (Kergomard 2000) (Tekkouk and Fizazi 2019) (MOURI 2020).

L'un des principaux avantages de la télédétection active radar est la possibilité de réaliser des acquisitions en tout temps, par ciel clair ou nuageux, et de jour comme de nuit. (Hachemi et al. 2009)

1.7 L'image satellitaire

L'imagerie satellitaire fait référence à la tâche de prendre des images de la Terre à partir de capteurs placés sur des satellites artificiels en orbite autour de la Terre (Ali and Nafa 2010).

Chapitre 01 : Généralité sur la télédétection

Les images satellites fournissent des informations importantes qui peuvent être utilisées dans plusieurs applications de télédétection, telles que la météorologie, l'océanographie, la cartographie, l'observation de l'agriculture, la détection des changements urbains, etc (Pony et al 2000).

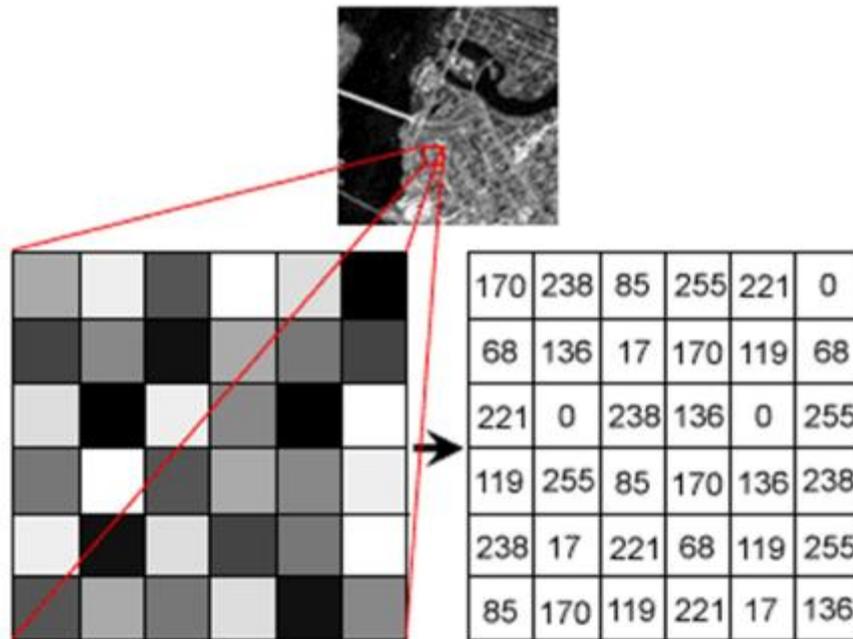


Figure 1.2 : Image numérique extraite d'une image satellitaire.

1.7.1 Résolution d'image satellite

Au regard des principes généraux de l'acquisition d'images satellitaires énoncés précédemment, il est possible de qualifier une image selon ses différentes résolutions, au nombre de quatre (Bayouhd 2013) (Campbell and Wynne 2011)

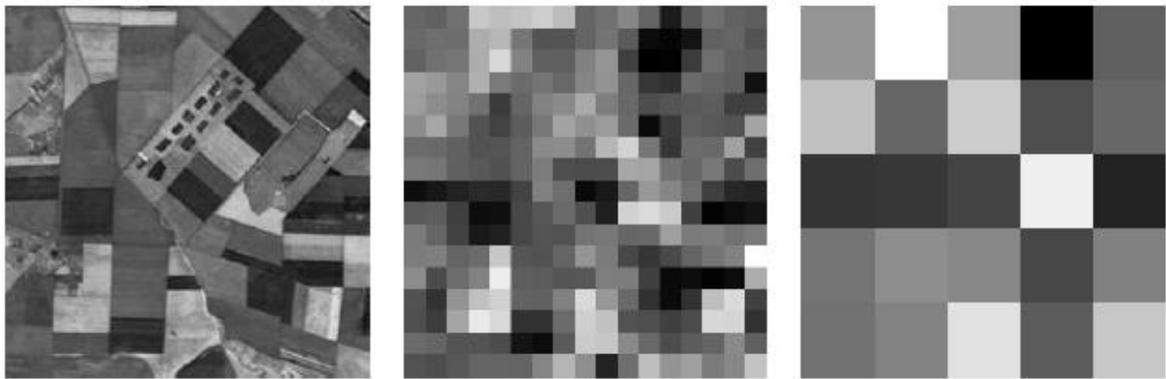
1.7.1.1 Résolution spatiale

La résolution spatiale d'une image satellite fait référence à la taille en m^2 de la surface de la Terre, mesurée au sol, qu'un pixel d'image recouvre. Cependant, la métrique la plus courante utilisée pour décrire la résolution spatiale est m , qui décrit la distance au sol représentée par chaque côté d'un pixel d'image carré (Pennober and Borius 2010).

Chapitre 01 : Généralité sur la télédétection

La résolution spatiale est affectée par la hauteur de l'orbite du satellite autour de la terre et le type de capteurs placés sur le satellite. Plus la résolution spatiale d'une image est élevée, plus la surface représentée par un pixel est petite.

En conséquence, une image satellite à haute résolution spatiale permet une vue détaillée du terrain de la Terre, puisque même les petits objets sont capturés et deviennent reconnaissables (Renaut 2017).



(a)Résolution 20 m.

(b)Résolution 300 m.

(c)Résolution 1 km.

Figure 1.3 : l'image (a) représente un extrait d'une image de réflectance SPOT/HRV de la plaine du Danube en Juin 2001. Les images (b) et (c) représentent des images du même site simulé par blocs respectivement de taille 16×16 (moyenne résolution) et de taille 50×50 (basse résolution).

1.7.1.2 Résolution spectrale

La résolution spectrale d'une image satellitaire est définie par le nombre de bandes / canaux spectraux qu'elle contient et la taille de l'intervalle de longueur d'onde mesurée en nm que chaque bande de l'image satellitaire. Cela signifie que les informations spectrales extraites de chaque satellite peuvent varier. La plupart des satellites peuvent fournir des images avec au moins 4 canaux, où en plus des canaux de base rouge-vert-bleu (RVB), un canal proche infrarouge est également inclus.

Chapitre 01 : Généralité sur la télédétection

Par exemple, le satellite IKONOS fournit des images satellite à 4 canaux, tandis que le satellite LANDSAT-7 capture des images à 7 canaux. En outre, même l'intervalle de longueur d'onde du même canal spectral peut varier d'un capteur à l'autre et cela signifie que le même canal spectral peut contenir des informations légèrement différentes lorsqu'il est capturé à partir de différents capteurs. Par exemple, le canal vert du satellite QuickBird se situe dans l'intervalle 520–600nm, tandis que le canal vert du satellite WorldView-2 se situe dans l'intervalle 510–580nm (Bouaita 2020).

1.7.1.3 Résolution temporelle

La résolution temporelle d'une image satellitaire fait référence au temps, généralement compté en jours, dont un satellite a besoin pour effectuer un cercle complet autour de la Terre et revenir au même endroit qu'auparavant afin de collecter d'images de la même surface terrestre. Ce type de résolution dépend principalement de l'orbite du satellite autour de la Terre (Lefebvre 2011).

1.7.1.4 Résolution radiométrique

La résolution radiométrique d'une image satellite fait référence aux niveaux de luminosité que les capteurs du satellite peuvent capturer. La résolution radiométrique est décrite en bits et les valeurs les plus courantes sont 8, 11, 12 et 16 bits. La plage de valeurs que peuvent obtenir les pixels d'une image satellite dépend de la résolution radiométrique du capteur utilisé pour capturer l'image. Plus précisément, étant donné que la résolution radiométrique d'une image est de n bits, l'intensité des pixels de l'image est de l'ordre de $[0, 2^n-1]$. Par conséquent, les valeurs de pixel d'une image de résolution de 8 bits appartiennent à la plage de $[0 - 255]$, tandis que les valeurs de pixel d'une image de résolution de 16 bits appartiennent à la plage de $[0 - 65535]$ (Sylla 2014).

Chapitre 01 : Généralité sur la télédétection

Bien que l'image à haute résolution permette de capturer de grands détails sur la surface de la terre et donc la détection de petites structures, comme des bâtiments, soit désormais possible, les images à haute résolution introduisent des limitations importantes. Une image à haute résolution est constituée d'un très grand nombre de pixels et le traitement d'une telle quantité de pixels peut prendre beaucoup de temps.

De plus, les conditions météorologiques et les nuages peuvent gravement affecter la qualité des images obtenues à partir des satellites.

Enfin, la disponibilité des données est un inconvénient majeur lorsqu'il s'agit d'applications de télédétection. Les images satellites, en particulier celles capturées à partir de capteurs satellites haute résolution (IKONOS, QuickBird, WorldView-1, -2, -3, etc.), sont des produits payants (Kourdian 2009).

1.8 Types d'images satellitaires

Les images satellitaires peuvent être classées selon le mode d'acquisition (images panchromatiques, images multi-spectrales, images hyper-spectrales) et la nature des capteurs par lesquels elles ont été prises (images mono-source ou images multi-sources) (Benhabib and Fizazi 2012).

Les images panchromatiques : elles sont acquises dans un intervalle de longueur d'onde unique situé entre les valeurs 0.4 et 0.7 μm . Ces images se caractérisent souvent par une résolution spatiale très importante et une faible résolution spectrale.

Les images multi-spectrales : elles sont obtenues à partir d'un ensemble de bandes de longueurs d'onde différentes. Généralement, le nombre de bande ne dépasse pas 10 (Restaino et al. 2016).

Les images hyper-spectrales : elles sont obtenues à partir d'un ensemble de bandes de longueurs d'onde différentes. Le nombre de bandes utilisées est de l'ordre de centaines.

Chapitre 01 : Généralité sur la télédétection

Par exemple, le satellite américain Hypérion compte 220 bandes spectrales (à partir de 0.4 à 2.5 mm) avec 30 m de résolution spatiale. Ces images se caractérisent par une richesse de la résolution spectrale et offrent ainsi de bien plus nombreuses informations sur les propriétés physiques des objets observés que celles offertes par les images multi-spectrales (Boulila 2012).

Les images multi-sources : elles sont acquises par différents capteurs afin de profiter de la complémentarité et de la redondance des informations contenues dans ces images. Comme exemple de telles images, nous pouvons citer la combinaison de deux images issues de deux capteurs passifs tels que le capteur Landsat et le capteur Spot, la combinaison de deux images issues de deux capteurs actifs, tels que, Alos et RadarSat 2 ou bien la combinaison d'une image optique et une image radar (Mahi 2014).

1.9 Traitement des images satellitaires

Le traitement numérique des images peut recourir à divers procédés dont la correction des données, le rehaussement numérique pour faciliter l'interprétation visuelle. Les images satellitaires brutes sont difficilement exploitables. Afin d'améliorer leur qualité, différents traitements numériques ont été proposés. Parmi ces traitements nous pouvons citer les prétraitements, Rehaussement de l'image, transformation de l'image et la classification et analyse de l'image (Wang et al. 2018) (Boudali et al. 2019).

A) Acquisition de l'image

L'image satellitaire constitue la principale source d'information pour l'occupation du sol grâce à la télédétection. Pour détecter un changement sur des images satellitaires on doit avoir au minimum deux images satellitaires acquises à deux dates différentes (images multi-dates) (Kergomard 2000).

Chapitre 01 : Généralité sur la télédétection

Les images acquises parviennent à la station de réception sous forme numérique. Elles sont alors traitées pour corriger les distorsions atmosphériques et géométriques lorsque c'est nécessaire. Elles sont ensuite converties dans un format standard et sont sauvegardées sur des supports de stockage (Tamminga et al. 2015)

B) Prétraitement

Les images obtenues après acquisition ne sont pas utilisables directement pour une interprétation aisée. On peut dire que le prétraitement doit fournir à partir des images brutes des images propres. Les traitements préliminaires ou prétraitements, ont pour but l'élimination ou du moins la réduction du « bruit » afin de faciliter l'extraction des informations à l'étape suivante. Ce bruit peut provenir de sources très diverses et dépendre notamment du système de télédétection en question aussi bien que de l'information recherchée (Arezki et al 2020).

B.1) Correction géométrique

Elles sont destinées à corriger l'image des déformations systématiques dues à la prise de vue (ellipsoïdes terrestre, défilement du satellite, variation du sol...). Elles sont faites soit à partir des paramètres d'orbite et d'altitudes enregistrées durant le vol, soit à l'aide de la loi de déformation ; pour rendre l'image conforme à un type de projection cartographique connu(Ottavianelli and Vescovi 2018).

B.2) corrections radiométriques

Un certain nombre de "bruits radiométriques" peut être présent sur l'image en raison soit de déficiences des capteurs, soit de problèmes de transmission des données, soit enfin d'interprétation (codage/décodage). En général ces corrections radiométriques, c'est-à-dire les changements de la valeur radiométrique de points aberrants, sont réalisées directement à la réception de l'image par réaffectation de codes correspondants aux pixels voisins ou aux points défectueux (Tu et al. 2018).

Chapitre 01 : Généralité sur la télédétection

B.3) Rehaussement de l'image

Les fonctions de rehaussement ont pour but d'améliorer l'apparence de l'imagerie pour aider l'interprétation et l'analyse visuelle. Elles permettent l'étirement des contrastes pour augmenter la distinction entre les différents thèmes d'intérêts d'une scène.

Le rehaussement des contrastes se fait en changeant les valeurs initiales de façon à utiliser toutes les valeurs possibles, ce qui permet d'augmenter le contraste entre les cibles et leur environnement (Bhandari, Kumar, and Singh 2015) (Gherdaoui 2018).

1.9.1 Classification

La classification consiste à regrouper des objets en un ensemble fini de catégories ou de classes, selon un ou plusieurs critère(s) de similarité ou de similitude à l'aide d'un classifieur. En télédétection, les objets à classer dans une image, peuvent être ponctuel (pixels) dans le cas des images à moyenne et à haute résolution spatiale ou structurel (segments) dans le cas des images à très haute résolution spatiale. Les critères de similarité (couleur, texture, forme) dépendent de la nature des objets à classer et de l'application envisagée (Karoui 2012) (Masse 2013).

1.9.1.1 Les méthodes de classification

Les méthodes de classification se catégorisent en deux grandes classes, selon la situation dans laquelle l'opérateur est placé: les méthodes de classification non supervisée (clustering en anglais) et les méthodes de classification supervisée, appelées aussi classement (classification en anglais). Dans la première catégorie, l'opérateur ne dispose d'aucune connaissance à priori sur les objets à classer. Les classes sont ainsi créées automatiquement par le classifieur puis étiquetées par thème à la fin du processus classificatoire.

Chapitre 01 : Généralité sur la télédétection

Dans la seconde catégorie, l'opérateur dispose de connaissances à priori sur les données à classer. Ces connaissances sont injectées dans le classifieur sous forme d'échantillons d'apprentissage ou de zones d'entraînement représentatives des classes à créer (Boudali 2020).

Les méthodes de classification utilisées en traitement d'images reposent sur leur grande majorité sur les notions de distance mathématique et de probabilité afin de mesurer la similarité entre deux objets. Il existe diverses distances, les plus courantes étant la distance euclidienne, la distance de Manhattan et la distance de Mahalanobis (Mahi 2014).

Dans le cadre d'une classification supervisée disposant de références spatiales, la matrice de confusion est un outil permettant de mesurer la qualité du système de classification utilisé.

a. La matrice de confusion

La matrice de confusion est un outil permettant de mesurer la concordance entre un ensemble d'éléments observés et un ensemble d'éléments de référence. Ici les éléments observés correspondent aux pixels issus de la classification et les éléments de référence à nos échantillons de vérification.

Notations : Soit la matrice de confusion \mathbf{m} qui pour chaque couple de classes ($\mathbf{c}_i, \mathbf{c}_j$) associe le nombre de pixels s correspondant à la classe \mathbf{c}_i dans l'image de référence mais classés en tant de \mathbf{c}_j par l'algorithme de classification. Chaque élément de cette matrice de confusion \mathbf{m} sera noté $\mathbf{m}_{\mathbf{c}_i, \mathbf{c}_j}$ avec $\mathbf{c}_i \in [1, C]$ et C le nombre de classes présentes.

Notons $\mathbf{m}_{\mathbf{c}_i, \cdot}$, la somme des pixels de référence appartenant à la classe \mathbf{c}_i et $\mathbf{m}_{\cdot, \mathbf{c}_j}$ la somme des pixels de référence classés en tant que \mathbf{c}_j par l'algorithme de classification.

Chapitre 01 : Généralité sur la télédétection

Le nombre total de pixels de vérification est noté N avec (Lewis and Brown 2001) :

$$N = \sum_{i \in [1,C]} m_{ci,.} = \sum_{j \in [1,C]} m_{.,cj} \quad (1.1)$$

La figure 1.4 illustre la représentation de la matrice de confusion.

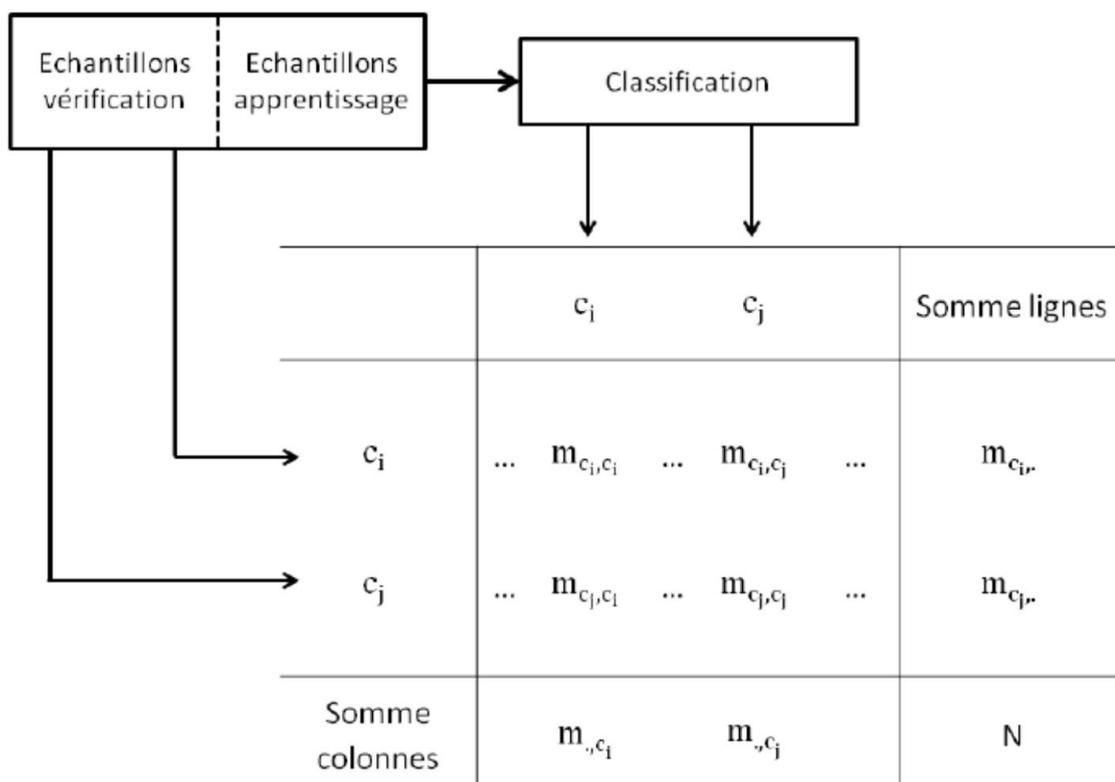


Figure 1.4 : Représentation de la matrice de confusion

1.9.1.2 Classification par réseaux de neurones multicouches (MLP)

Dans cette thèse, on s'intéresse à la classification supervisée en utilisant les réseaux de neurones multicouches (MLP : Multi Layer Perceptron). Le MLP est une extension du célèbre Perceptron, avec une ou plusieurs couches intermédiaires appelées "couche cachées". Ce sont les réseaux de neurone les plus connus.

Les réseaux de neurones multicouches sont utilisés depuis de nombreuses années dans le domaine de la classification étant donné leurs bons résultats.

Chapitre 01 : Généralité sur la télédétection

Le *MLP* ou *PMC* (perceptron multicouches) est un réseau orienté de neurones artificiels en couches, où l'information circule dans un seul sens, de la couche d'entrée vers la couche de sortie. De nombreuses études ont été menées dans ce sens et sont disponibles dans la littérature (Solaiman and Richard 2003), (Jiang et al. 2018), (Hassib et al. 2020), (Song et al. 2021).

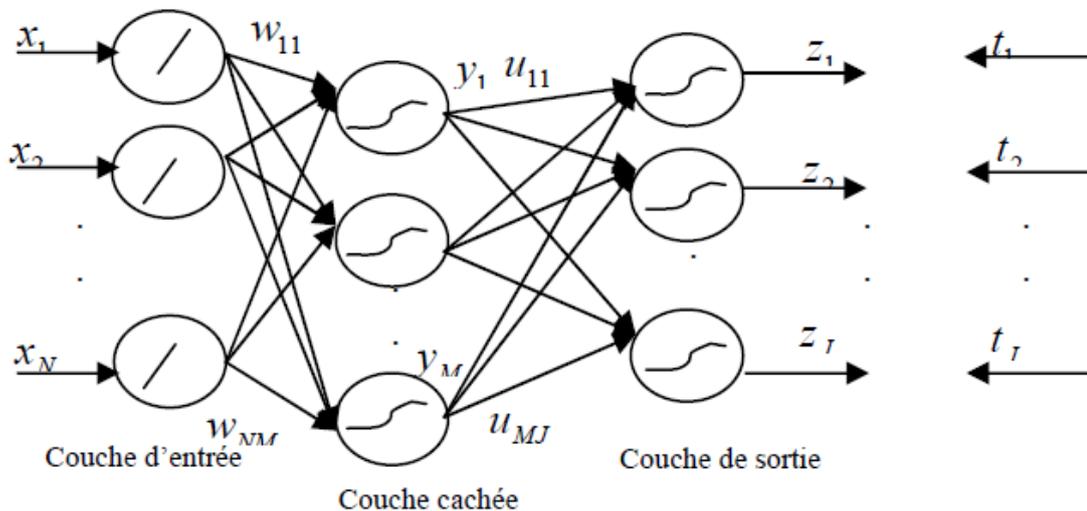


Figure 1.5 : Présentation schématique d'un MLP.

w_{nm} représente les poids reliant la couche d'entrée avec la couche cachée ;

u_{mj} représente les poids reliant la couche cachée avec celle de la sortie.

Les composants du vecteur d'entrée X du MLP seront pondérés par les poids w_{nm} et ensuite transmis à la couche cachée.

Les sorties de la couche cachée seront aussi pondérées par les poids u_{mj} et transmis ensuite à la couche de sortie.

L'apprentissage consiste à adapter les valeurs des poids et biais afin d'obtenir le comportement désiré du MLP. Un algorithme d'apprentissage connu sous le nom d'algorithme de rétro propagation du gradient a été mis en place en 1985 par (Rumelhart et al 1986).

Chapitre 01 : Généralité sur la télédétection

L'apprentissage est défini comme un problème d'optimisation qui consiste à trouver les coefficients du réseau minimisant une fonction d'erreur globale. La définition de cette fonction, aussi appelée fonction de coût est primordiale, car elle sert à mesurer l'écart entre les sorties désirées, notées d_j et les sorties calculées y_j .

La fonction communément utilisée est la fonction dite d'erreur quadratique donnée par l'équation suivante (Guellil and Zaoui 2009) :

$$e(x_i) = \frac{1}{2} \sum_{j=1}^k [d_j(x_i) - y_j(x_i)]^2 \quad (1.2)$$

On peut définir aussi la fonction d'erreur quadratique moyenne, donnée par :

$$EQM = \frac{e(x_i)}{R} \quad (1.3)$$

R q est le nombre d'échantillons d'apprentissage

1.9.2 La détection des changements

Dans le domaine de télédétection, les observations temporelles sont assurées par des capteurs qui nous fournissent des images multi-temporelles d'une région de la surface terrestre pour laquelle on désire étudier des phénomènes dynamiques particuliers. Les images peuvent changer radicalement en fonction des variations saisonnières, des conditions météorologiques, des méthodes d'acquisition et de plusieurs autres facteurs. La gestion de ces variations est l'un des principaux défis de l'analyse d'images par télédétection. La détection des changements devenue une des principales opérations de traitement des images satellitaires (Gherdaoui 2018) (Houcine 2020).

1.9.2.1 Changements d'occupation des sols

Chapitre 01 : Généralité sur la télédétection

Le terme « occupation des sols » correspond à une description purement physique de l'espace. Il désigne l'occupation physique observée de la surface terrestre comprenant ainsi les surfaces en végétation (végétation arborée, végétation rase...), les sols nus (roches) et les surfaces en eau (réseau hydrographique, plans d'eau...). Analyse du changement de l'occupation des sols permet d'évaluer rapidement les changements d'occupation des sols, sur la base de l'évaluation quantitative des gains et des pertes, de la persistance et des transitions. Ces changements peuvent être présentés dans les cartes et sous forme graphique (Ronald Eastman et al. 2009).

De plus, cette étape permet également d'analyser la tendance spatiale globale du changement de l'occupation des sols à l'échelle du secteur étudié. Pour l'analyse du changement de l'occupation des sols, deux cartes de l'occupation des sols à des dates différentes sont utilisées comme base pour la compréhension de la nature du changement. Les changements de l'occupation des sols ayant eu lieu entre les deux années analysées ont été identifiés et intégrés dans le sous-modèle de transition. Après plus de 30 années de recherche sur l'étude des changements d'occupation des sols (Solly et al. 2021) (Hassan et al 2019), une nouvelle discipline scientifique appelé « Land Change Science (LCS) » s'est peu à peu imposée. La modélisation des changements d'occupation des sols doit ainsi être appréhendée comme un cadre conceptuel général qui permet de dégager des règles de transition qui sont ensuite intégrées dans des outils de simulation spatialement explicites (Corgne 2014).

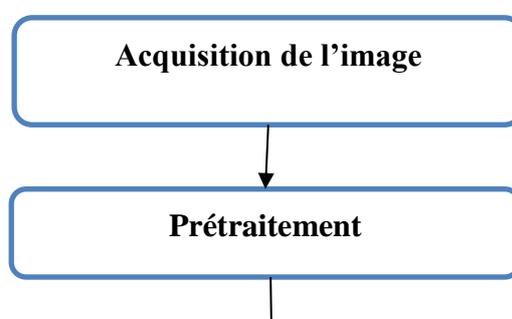
La détection des changements peut être appliquée dans différents domaines, par exemple (Solofo 2019):

Chapitre 01 : Généralité sur la télédétection

- **Agriculture** : pour le repérage des grandes cultures.
- **Environnement** : pour délimiter les ensembles écologiques ou pour appuyer la mise en place de parcs de conservation.
- **Urbanisation** : évaluation de l'étalement urbain.
- **Géologie** : pour planifier les campagnes de terrain et compiler les informations structurales.
- **Cartographie** : pour la mise à jour des cartes
- **Foresterie** : localisation de la déforestation, la cartographie des grands feux de forêt.

A) Démarche générale pour établir une carte d'occupation du sol

Pour établir une cartographie de l'occupation du sol par télédétection (selon une démarche assistée) (Sarr 2009), plusieurs étapes sont nécessaires : acquisition de l'image, prétraitement, traitement d'images et analyse et interprétation.



Chapitre 01 : Généralité sur la télédétection

Figure 1.6 : Les processus de la détection des changements

B) Traitement d'images : Détection de changement

Parmi les méthodes de traitement des données de télédétection utilisées aujourd'hui, on distingue principalement les méthodes de détection de changement. De nombreuses études ont été menées dans ce sens et sont disponibles dans la littérature. (Singh 1989), (Lyon et al. 1998), (Jensen and Im 2007), (Hassan et al 2019) et (Zhao et al. 2021).

Fondamentalement, les techniques de détection des changements ont été divisées en plusieurs catégories (voir chapitre 03).

C) Analyse et interprétation

Interpréter une image c'est identifier des objets, définir leurs natures, leurs limites, leurs relations avec le milieu mais aussi leurs nombres ou leurs volumes. L'interprétation et l'analyse de l'imagerie ont pour but d'identifier et de mesurer différentes cibles dans une image pour pouvoir en extraire l'information utile. Les analyses visuelles, et numériques de l'imagerie ne s'excluent mutuellement (Ouldmelha and Mansour 2015).

Les deux méthodes ont chacune leurs mérites, et c'est en combinant les deux que se font la plupart des analyses de l'imagerie la décision finale. Quant à l'importance et l'utilité de l'information extraite à la fin du processus d'analyse, revient toujours aux analystes.

Le tableau 1.1 donne une étude détaillée sur les travaux de détection des changements.

Chapitre 01 : Généralité sur la télédétection

Auteur	Application
(Patil et al. 2017)	Prédisez la future couverture terrestre.
(T. Chen, Trinder, and Niu 2017)	Cartographie des glissements de terrain
(Sun et al. 2018)	Cartographie du couvert végétal pour les zones arides et semi-arides
(B. Huang, Zhao, and Song 2018)	Évaluation des dommages, en particulier la détection des glissements de terrain
(Aslami and Ghorbani 2018))	Détection de l'utilisation des terres / du changement de couverture terrestre
(Qin et al. 2018)	Évaluation des dommages
(Si Salah et al. 2019)	Détection des changements dans les zones urbaines à partir des données de télédétection.
(Mallucci et al 2019)	Détection des changements hydrologiques dans un grand bassin hydrographique alpin.
(Ansari et al 2020)	Détection des changements dans l'urbains à l'aide de caractéristiques de textures

Tableau 1.1 : Etude détaillée des travaux sur la détection des changements.

1.10 Conclusion

La télédétection c'est l'art d'acquérir à distance des informations, en général des images, et l'art de traiter ces informations pour les utiliser dans différents domaines tel que :

Les fins commerciales (exploitation des ressources terrestres).

Chapitre 01 : Généralité sur la télédétection

Stratégiques (surveillance des territoires).

Humaines (aide au développement, prévention des catastrophes).

Ce chapitre propose un panorama sur la télédétection et l'imagerie satellitaire. Nous avons entamé les principes de base de la télédétection en faisant appel aux différentes méthodes de traitement d'images satellitaires.

Dans notre étude on a opté en particulier à utiliser les réseaux de neurones comme un processus classificatoire qui nécessite l'optimisation de leurs paramètres d'initialisation qui fera l'objet du chapitre suivant.

Chapitre 02 :

les Métaheuristiques

Chapitre 02 : les Métaheuristiques

2.1 Introduction

L'optimisation est une discipline en plein essor qui entre en jeu dans beaucoup de domaines, comme dans la conception de circuits électroniques, la recherche opérationnelle, la biologie, mais aussi pour répondre aux besoins croissants des secteurs économique et industriel (maximisation des performances, minimisation des coûts).

Sans prétendre à une totale exhaustivité, ce deuxième chapitre s'efforce de présenter un état de l'art sur les métaheuristiques pour la résolution de problèmes d'optimisation difficile. On distingue généralement deux grandes familles de métaheuristiques : celles qui manipulent en parallèle toute une population de solutions (on peut citer les algorithmes génétiques, la méthode des colonies de fourmis, l'optimisation par essaim particulière, etc.) et les autres qui se basent sur l'évolution itérative d'une solution unique (la méthode Tabou et le Recuit Simulé, etc.)

2.2 Problème d'optimisation

Un problème d'optimisation se définit comme la recherche, parmi un ensemble de solutions possibles S (appelé aussi espace de décision ou espace de recherche), de la (ou des) solution(s) x^* qui rend(ent) minimale (ou maximale) une fonction mesurant la qualité de cette solution (Meignan 2008).

Cette fonction est appelée fonction objectif ou fonction coût. Si l'on pose $f : S \rightarrow R$ la fonction objective à minimiser (respectivement à maximiser) à valeurs dans R , le problème revient alors à trouver l'optimum $x^* \in S$ tel que $f(x^*)$ soit minimal (respectivement maximal).

Chapitre 02 : les Métaheuristiques

Lorsque l'on veut résoudre un problème d'optimisation, on recherche la meilleure solution possible à ce problème, c'est-à-dire l'optimum global. Cependant, il peut exister des solutions intermédiaires, qui sont également des optimums, mais uniquement pour un sous-espace restreint de l'espace de recherche : on parle alors d'optimums locaux. Cette notion est illustrée dans la figure 2.1. La seule hypothèse faite sur S est qu'il s'agit d'un espace topologique, i.e. sur lequel est définie une notion de voisinage. Cette hypothèse est nécessaire pour définir la notion de solutions locales du problème d'optimisation. On peut alors définir un optimum local (relativement au voisinage V) comme la solution x^* de S telle que $f(x^*) \leq f(x); \forall x \in V(x^*)$.

Les scientifiques ont toujours été confrontés à des problèmes de complexité croissante qui surgissent dans des secteurs techniques très divers. Ces problèmes peuvent être formulés sous forme de problème d'optimisation combinatoire (Hao et al 1999).

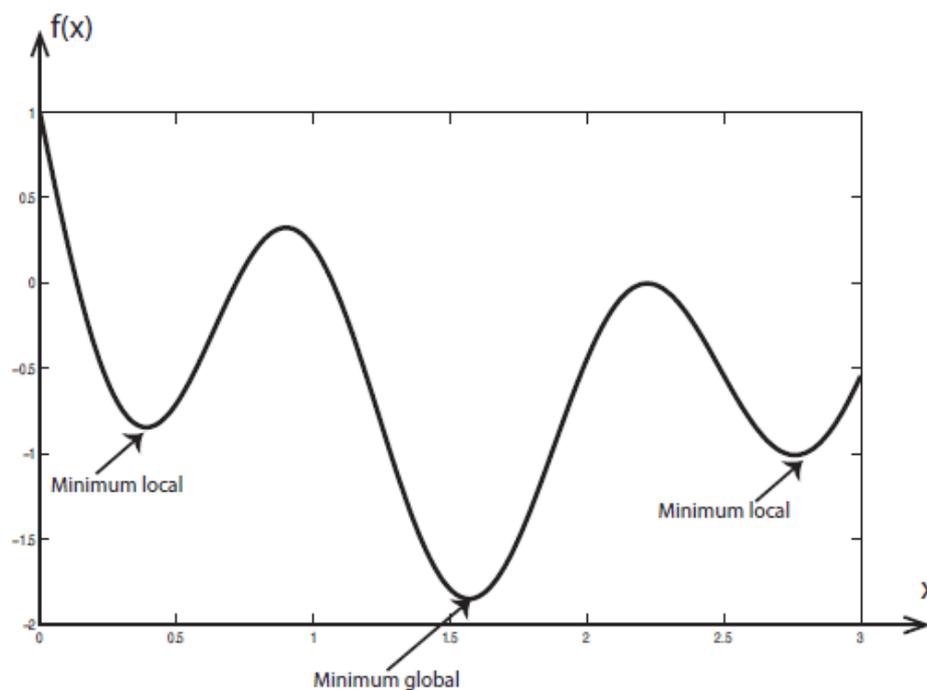


Figure 2.1: Différence entre un optimum global et des optima locaux

Chapitre 02 : les Métaheuristiques

2.2.1 Classification des méthodes d'optimisation

La résolution d'un problème d'optimisation est réalisée à l'aide des méthodes d'optimisation dont la classification est illustrée dans la figure 2.2. On distingue en premier lieu l'optimisation continue de l'optimisation discrète (ou combinatoire).

Pour l'optimisation continue, on sépare sommairement le cas linéaire (qui relève notamment de la programmation linéaire) du cas non linéaire, où l'on retrouve le cadre de l'optimisation difficile (Hannane and Fizazi 2016).

L'optimisation combinatoire est une discipline utilisant conjointement différentes techniques des mathématiques discrètes, de la recherche opérationnelle et de l'informatique, afin de résoudre des problèmes d'optimisation.

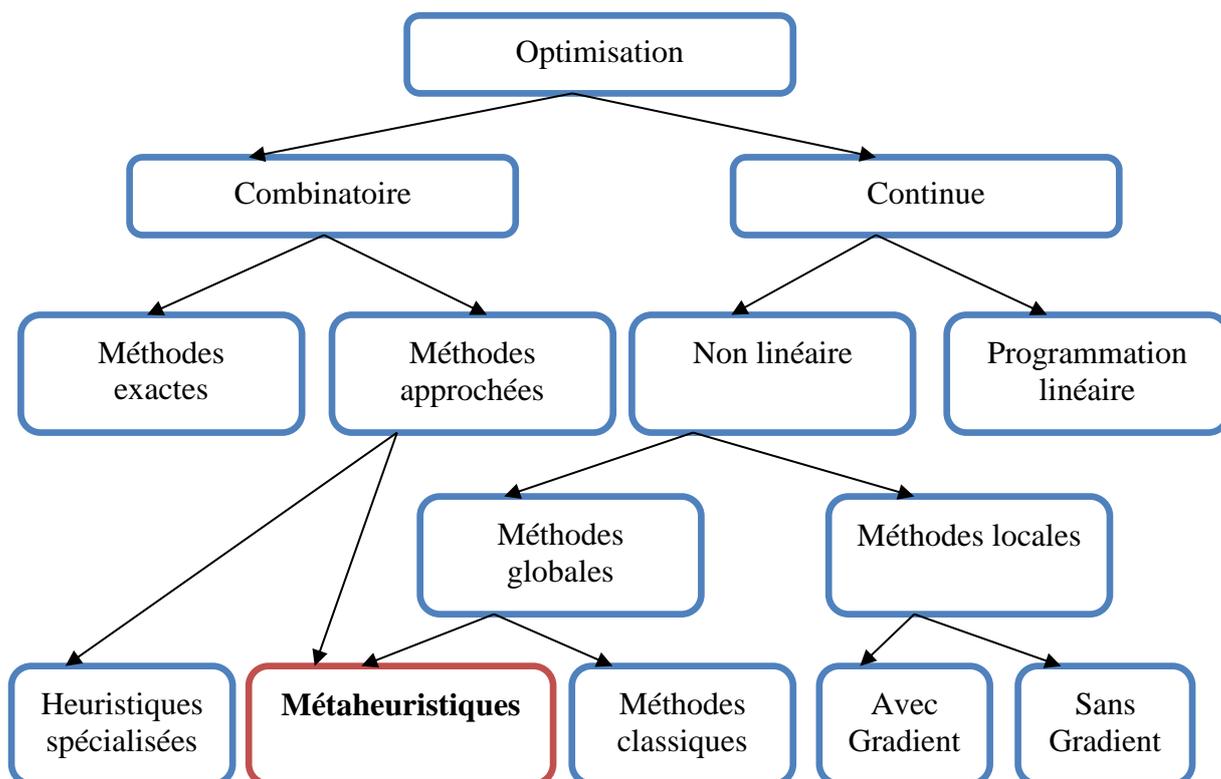


Figure 2.2: Classification des méthodes d'optimisation

Chapitre 02 : les Métaheuristiques

Pour les problèmes d'optimisation combinatoire de taille raisonnable, les méthodes exactes peuvent trouver des solutions optimales. Ces méthodes explorent de façon systématique l'espace des combinaisons jusqu'à trouver une solution optimale.

Le principe essentiel d'une méthode exacte consiste généralement à énumérer (Lalami 2012), souvent de manière implicite, l'ensemble des solutions de l'espace de recherche.

Les méthodes exactes sont alors susceptibles de trouver des solutions optimales pour des problèmes de taille raisonnable.

Les méthodes exactes ne sont pas suffisantes pour résoudre certains problèmes d'optimisation complexes. Parmi ces limites, nous pouvons citer l'absence de convexité, la non-dérivabilité, la discontinuité ou encore la difficulté de définir précisément la fonction objective (El Dor 2012). De plus, les méthodes exactes peuvent avoir un temps de résolution trop long, le problème d'optimisation dans ce cas, est dit NP-difficile (NP-hard). Pour résoudre de tels problèmes, il est nécessaire d'avoir recours à des méthodes approchées (heuristiques).

Cependant, les techniques de filtrage et les heuristiques d'ordre ne réduisent pas toujours suffisamment la combinatoire (Hao and Solnon 2014), et certaines instances de problèmes ne peuvent être résolues en un temps acceptable par ces approches exhaustives. Lorsque l'on dispose d'un temps de calcul limité ou lorsqu'on est confronté à des problèmes difficiles ou de taille importante, on peut avoir recours aux méthodes approchées, en se contentant de rechercher une solution de « bonne qualité » ; dans ce cas le choix est parfois possible entre une heuristique spécialisée, entièrement dédiée au problème considéré, et une méta heuristique (Dréo 2003).

Les méta-heuristiques, interviennent dans toutes les situations où l'on ne connaît pas d'heuristique efficace pour résoudre un problème donné.

Chapitre 02 : les Métaheuristiques

Les heuristiques et les métaheuristiques font parties de la famille des méthodes stochastiques, c'est-à-dire que l'algorithme ne va pas retourner la même solution entre deux exécutions indépendantes à cause de l'aspect aléatoire présent dans la méthode.

2.2.2 Heuristiques versus Méta heuristiques

Le mot heuristique vient du grec eurisko qui signifie « je trouve » d'où le célèbre Eureka d'Archimède (Femmam 2016). Une heuristique, ou méthode approximative, est un algorithme qui fournit rapidement (en temps polynomial) une solution réalisable, pas nécessairement optimale, pour un problème d'optimisation NP-difficile.

Les approches heuristiques, contournent le problème de l'explosion combinatoire en faisant délibérément des impasses et n'explorent qu'une partie de l'espace des combinaisons. Elle est généralement conçue pour un problème particulier, en s'appuyant sur sa structure propre. On parle de métaheuristique pour les méthodes approximatives générales, pouvant s'appliquer à différents problèmes.

Le mot métaheuristique est dérivé de la composition de deux mots grecs : méta, du grec signifiant « au-delà » (ou « à un plus haut niveau ») et heuristique. En effet, ces algorithmes se veulent des méthodes génériques pouvant optimiser une large gamme de problèmes différents, sans nécessiter de changements profonds dans l'algorithme employé (Hao and Solnon 2014) (Drif and Bensaïfia 2018).

Les métaheuristiques constituent une classe de méthodes qui fournissent des solutions de bonne qualité en un temps raisonnable à des problèmes combinatoires réputés difficiles pour lesquels on ne connaît pas de méthode classique plus efficace. Elles sont généralement des algorithmes stochastiques itératifs, qui progressent vers un optimum global, c'est à dire l'extremum global d'une fonction en évaluant une certaine fonction objective.

Chapitre 02 : les Métaheuristiques

Elles se comportent comme des algorithmes de recherche, tentant d'apprendre les caractéristiques d'un problème à fin d'en trouver une approximation de la meilleure solution d'une manière proche des algorithmes d'approximations (Mamouni and Ould Mohamed 2018).

L'intérêt croissant apporté aux métaheuristiques est tout à fait justifié par le développement des machines avec des capacités calculatoires énormes, ce qui a permis de concevoir des métaheuristiques de plus en plus qui ont fait preuve d'une certaine efficacité lors de la résolution de plusieurs problèmes à caractère NP-difficile. Finalement, on ne doit pas oublier qu'un des intérêts majeurs des métaheuristiques est leur facilité d'utilisation (Deroussi 2016).

Un des investissements des métaheuristiques est donc de faciliter le choix d'une méthode et de simplifier son réglage pour l'adapter à un problème d'optimisation donné.

2.2.3 Classification des métaheuristiques

On peut distinguer les métaheuristiques qui font évoluer une seule solution sur l'espace de recherche à chaque itération et les métaheuristiques à base de population de solutions. En général, les métaheuristiques à base de solution unique sont plutôt axées sur l'exploitation de l'espace de recherche. Les métaheuristiques à base de population sont plutôt exploratoires et permettent une meilleure diversification de l'espace de recherche (Lones 2014).

2.2.3.1 Les métaheuristiques à solution unique

Les méthodes d'optimisation à solution unique sont appelées les méthodes trajectoires (décrire une trajectoire en l'espace de recherche au cours du processus de recherche). Les métaheuristiques à solution unique commencent avec une seule solution initiale et s'en éloignent progressivement, en construisant une trajectoire dans l'espace de recherche.

Chapitre 02 : les Métaheuristiques

Les méthodes de trajectoire englobent essentiellement la méthode de descente, la méthode du recuit simulé, la recherche tabou, la méthode GRASP, la recherche à voisinage variable, la recherche locale itérée, et leurs variantes (Jourdan 2010)..

A) Recuit simulé

La méthode du recuit simulé est inspirée de la métallurgie, où, pour atteindre des états de basse énergie d'un solide, il faut monter la température du solide à des valeurs très élevées, ensuite le laisser refroidir doucement. Ce processus est appelé "recuit". La métaheuristique est dite "recuit simulé" établie individuellement par Kirk Patrick et al, en 1983 (Kirkpatrick et al 1983) (Bahlali 2017). Elle repose sur la procédure de Metropolis (Metropolis et al. 1953). Cette procédure permet de sortir des minimums locaux avec une probabilité d'autant plus grande que la température T est élevée. Quand on atteint les très basses températures, les états les plus probables forment d'excellentes solutions (Aarts et al 2018). L'algorithme de Metropolis échantillonne la fonction objective par le biais d'une distribution de Boltzmann de paramètre T . Le point décisif de l'algorithme est la loi de diminution de la température. L'algorithme est efficace et facile à s'adapter à un nombre important de problèmes. En contrepartie, cet algorithme présente l'inconvénient de disposer d'un nombre élevé de paramètres (température initiale, règle de décroissance de la température, durée des paliers de température, etc.) qui rendent les réglages de l'algorithme assez empiriques. L'autre inconvénient majeur de cette méthode est sa lenteur (Zheng and Ren 2020).

Chapitre 02 : les Métaheuristiques

Le pseudo code de l'algorithme du recuit simulé est comme suit :

Définir la fonction objectif (f).

Choix des mécanismes de perturbation d'une configuration ΔS .

Tirer une configuration aléatoire S .

Initialiser la température (T_0).

Tant que l'équilibre thermodynamique pas atteint **faire**

Tirer une nouvelle configuration S' .

Appliquer la règle de Metropolis.

Si $f(S) < f(S')$

$f_{\min} = f(S')$

$S_{\text{opt}} = S'$

Fin de si.

Fin tant que

Décroître la température.

Figure 2.3 : l'algorithme du recuit simulé

B) Le GRASP

La procédure de recherche gloutonne aléatoire adaptative (GRASP : Greedy Randomized Adaptive Search Procedure), proposée par Feo et Resende dans (Feo and Resende 1995), est une métaheuristique à départs multiples, dépourvue de mémoire, fondée sur les algorithmes gloutons randomisés et les techniques de recherche de voisinage. Cette méthode alterne les phases de construction et d'amélioration jusqu'à atteindre le critère d'arrêt.

Chapitre 02 : les Métaheuristiques

L'étape de la construction du GRASP est similaire à une méthode gloutonne randomisée, elle génère une solution réalisable issue d'une liste de choix potentiels appelée restricted candidate list (RCL). Cette liste est triée, c'est la partie gloutonne de l'algorithme. L'étape d'amélioration utilise la solution générée lors de la phase précédente comme une solution initiale pour effectuer une recherche locale. Cette dernière peut être une descente, une recherche tabou, ou toute autre heuristique (Ghoumari 2018).

2.2.3.2 Les métaheuristiques à population de solutions

Contrairement aux algorithmes partant d'une solution singulière, les métaheuristiques à population de solutions améliorent, au fur et à mesure des itérations, une population de solutions (Widmer 2001).

Nous nous intéressons à cette dernière catégorie en présentant quatre méthodes : l'optimisation par essais particuliers, l'optimisation par colonies de fourmis, l'algorithmes de recherche gravitationnel et l'AIS.

A) L'optimisation par essais particuliers

L'optimisation par essais particuliers a été introduite par les auteurs Kennedy et Eberhart, en 1995 (Kennedy and Eberhart 1995). Cet algorithme s'inspire à l'origine du monde du vivant. Il s'appuie notamment sur un modèle développé par le biologiste Craig Reynolds à la fin des années 1980 pour la simulation du déplacement d'un groupe d'oiseaux.

L'algorithme PSO déplace un essaim de particules dans l'espace de recherche. Le déplacement de chaque particule est influencé par sa vitesse, la meilleure position qui a été retenue et la meilleure position connue par toutes les particules de l'essaim (Gharib and Benhra 2015).

Chapitre 02 : les Métaheuristiques

Soit x_i un vecteur de position de la $i^{\text{ème}}$ particule de l'essaim v_i un vecteur de vitesse de cette particule. D la dimension de ce problème. x_i et v_i sont des vecteurs à D éléments dont la $j^{\text{ème}}$ est notée respectivement x_{ij} et v_{ij} .

Soit p_i un vecteur de dimension D qui correspond à la meilleure position atteinte par la particule i et p_{ij} sa coordonnée sur la dimension j . On note g le vecteur de dimension D qui correspond à la meilleure position connue de l'essaim.

A l'itération $t+1$ le déplacement des particules est calculé à l'aide des équations :

$$V_{ij}(t + 1) = W \cdot V_{ij}(t) + C_1 \cdot r_1(p_{ij} - x_{ij}(t)) + C_2 \cdot r_2(g_{ij} - x_{ij}(t)) \quad (2.1)$$

$$x_{ij}(t + 1) = x_{ij}(t) + V_{ij}(t + 1) \quad (2.2)$$

w : coefficient de l'inertie

C_1, C_2 : coefficients d'accélération.

$r_1, r_2 \in [0,1]$ (générés aléatoirement).

Au début de l'algorithme (Mehouas 2019), un essaim est réparti au hasard dans l'espace de recherche, chaque particule ayant également une position et une vitesse aléatoires.

Ensuite, à chaque pas de temps :

Chaque particule dispose d'une mémoire concernant sa meilleure solution visitée ainsi que la capacité de communiquer avec les particules constituant son entourage.

À partir d'optimums locaux et empiriques, l'ensemble des particules va, normalement, converger vers la solution optimale globale du problème traité.

Un essaim de particule est caractérisé par :

- Le nombre de particules de l'essaim, noté nb .
- La vitesse maximale d'une particule, notée v_{\max} .
- L'inertie d'une particule, notée Ψ .

Chapitre 02 : les Métaheuristiques

- Les coefficients de confiance, notés ρ_1 et ρ_2 , qui pondèrent le comportement conservateur (la tendance à retourner vers la meilleure solution visitée).
- Une particule est caractérisée, à l'instant t , par :
 - $X_i(t)$: à position dans l'espace de recherche.
 - $V_i(t)$: sa vitesse.
- x_{pbest} : la position de la meilleure solution par laquelle elle est passée.
- $pbest$: la valeur de fitness de sa meilleure solution.

L'algorithme suivant présente une description générale :

Entrées : $0 < \rho < 1$

Répéter

Pour $i=1$ jusqu'à nb **faire**

Si $f(X_i) > pbest_i$ **alors**

$Pbest_i = f(X_i)$

$X_{pbest_i} = X_i$

Fin si

$V_i = V_i + \rho(X_{pbest_i} - X_i)$

$X_i = X_i + V_i$

fin pour

Figure 2.4 : L'algorithme de PSO

L'algorithme doit alors s'exécuter tant que l'un des critères de convergence suivant n'a pas été atteint (El Moubarek 2008):

- Le nombre d'itération maximal a été atteint.
- la variation de la vitesse est proche de 0.
- le fitness de la solution est suffisant.

Chapitre 02 : les Métaheuristiques

B) L'Optimisation par Colonie de Fourmis

La méthode de colonies de fourmis est apparue d'une constatation simple: les insectes sociaux, et en particulier les fourmis, résolvent naturellement des problèmes complexes.

Un tel comportement est possible car les fourmis communiquent entre elles de manière indirecte par le dépôt de substances chimiques, appelées phéromones, sur le sol. Ce type de communication indirecte est appelé stigmergie (Schwab et al 2013).

En effet, si un obstacle est introduit sur le chemin des fourmis, ces dernières vont, après une phase de recherche, avoir tendance toutes à prendre le plus court chemin entre le nid et l'obstacle (Figure 2.5). Plus le taux de phéromone à un endroit donné est important, plus une fourmi va avoir une grande probabilité à être attirée par cette zone. Les fourmis qui sont arrivées le plus rapidement au nid en passant par la source de nourriture sont celles qui ont pris la branche la plus courte du trajet. Il en découle donc que la quantité de phéromones sur ce trajet est plus importante que sur le trajet le plus long. De ce fait, le plus court chemin a une probabilité plus grande d'être pris par les fourmis que les autres chemins, et il sera donc pris par toutes les fourmis.

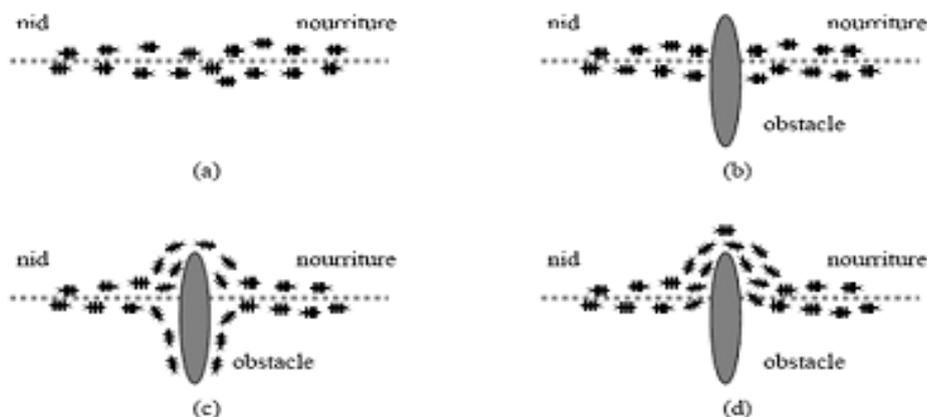


Figure 2.5 : Illustration de la capacité des fourmis à chercher de la nourriture en minimisant leur parcours.

Chapitre 02 : les Métaheuristiques

L'optimisation par colonie de fourmis OCF (Ant Colony Optimization ACO) est une méthode stochastique qui requiert de plus en plus l'attention de la communauté scientifique (Aadil et al. 2016) (Mendonça et al. 2020).

Il estime que rechercher une source de nourriture est analogue à rechercher une solution dans un espace de recherche commun. ACO s'appuie sur des agents appelés fourmis artificielles ayant des capacités supérieures.

La quantité de phéromones déposée par les fourmis réelles représente une valeur stockée dans une variable pour les fourmis artificielles et dépend du problème à traiter. L'évaporation des phéromones est une décrémentation de cette valeur (Dorigo and Stützle 2019).

L'algorithme suivant présente une description générale :

Définir les paramètres, initialiser les traces de phéromones

Tant que (critère d'arrêt n'est pas vérifié)

Construction des solutions par les fourmis

Action Spécifiques {facultatif}

Mis à jour de phéromones

Fin tant que

Figure 2.6 : L'algorithme d'ACO

Construction des solutions par les fourmis: Dans cette étape, m fourmis artificielles construisent des solutions à partir de l'ensemble des composantes de solution possibles.

Chapitre 02 : les Métaheuristiques

La construction d'une solution commence par une solution partielle vide $s_p = \emptyset$. Puis, à chaque étape de la construction, cette solution partielle s_p est étendue en y ajoutant une composante de solution parmi l'ensemble des voisins réalisables $N(s_p) \subseteq C$.

Le choix d'une composante dans $N(s_p)$ se fait de manière probabiliste à chaque étape de la construction. Chaque composante $c_{ij} \in N(s_p)$ a une probabilité $p(c_{ij}/s_p)$ d'être choisie. Les lois de probabilités dépendent de la variante utilisée. Une fois l'étape de construction effectuée par les fourmis, et avant l'étape de mise à jour des traces de phéromones, des actions spécifiques au problème ou des actions centralisées (qui ne peuvent pas être effectuées séparément par chaque fourmi) peuvent être effectuées. Le plus souvent, ces actions consistent en une recherche locale parmi les solutions construites, et où seules les solutions localement optimisées sont utilisées dans la mise à jour des traces de phéromones (Benbouzid et al 2006).

Le but de la mise à jour des traces de phéromones, dernière étape d'une itération, est d'augmenter les valeurs de phéromones associées à de bonnes solutions, tout en réduisant celles associées à des mauvaises.

Généralement, le critère d'arrêt est défini par un nombre maximal d'itérations.

C) Algorithmes de recherche gravitationnel

L'optimisation par algorithme de recherche gravitationnel est une nouvelle métaheuristique d'optimisation inspirée de la nature, développée par (Rashedi et al 2009). Cet algorithme est basé sur la loi de gravité de Newton qui décrit la gravitation comme une attraction entre des corps ayant une masse : « Deux particules dans l'univers s'attirent avec des forces qui sont directement proportionnelles au produit des masses des particules et inversement proportionnelles au carré de la distance qui les sépare ».

Chapitre 02 : les Métaheuristiques

Dans le GSA (Semchedine 2018), les masses des objets (solutions) sont proportionnelles à leurs valeurs de fonctions objectives (fitness).

A chaque itération, les masses s'attirent, entre elles, par les forces de gravitation. La masse, la plus lourde à la force d'attraction la plus grande. Par conséquent, les masses plus lourdes qui sont probablement près de l'optimum global attirent les autres masses selon leurs distances. Chaque objet est déterminé par quatre spécifications: position, inertie, masse gravitationnelle active et la masse gravitationnelle passive.

La position correspond à une solution du problème, l'inertie et les masses gravitationnelles sont déterminées en utilisant la fonction objective (Benmammar and Amraoui 2020). Plus précisément, les masses obéissent les deux lois suivantes:

- **Loi de gravité** : chaque objet attire un autre par une force gravitationnelle directement proportionnelle au produit de leurs masses et inversement proportionnelle à la distance entre eux.
- **Loi de mouvement**: la vitesse courante de toute masse est la somme de la fraction de sa vitesse précédente et la variation de la vitesse.

Chapitre 02 : les Métaheuristiques

L'algorithme GSA est défini par les étapes suivantes (Sabri et al 2013) :

- a) Identification de l'espace de recherche.
- b) Initialisation les paramètres G_0 et α .
- c) Évaluation de la fonction objective des objets.
- d) Mise à jour de $G(t)$, $best(t)$, $worst(t)$ et M_i pour $i = 1, 2, \dots, N$.
- e) Calcul de la force total dans les différentes directions.
- f) Calcul de l'accélération et la vitesse.
- g) Mis à jour de la vitesse et la position des agents.
- h) Répétez les étapes c à g jusqu'à ce que le critère d'arrêt est atteint.
- i) Fin

Figure 2.7 : L'algorithme de GSA

D) Systèmes Immunitaires Artificiels (AIS)

Proposée par D. Dasgupta (Dasgupta 1993), l'algorithme AIS (Artificial Immune Systems) est une modélisation du système immunitaire naturel qui inclut : l'algorithme de la sélection négative, l'algorithme de la sélection clonale, les réseaux immunitaires, et la théorie de danger.

L'algorithme est composé d'agents appelés leucocytes responsables de la défense de l'organisme contre les agents pathogènes (virus, bactéries, parasites). Ces algorithmes exploitent les caractéristiques du système immunitaire naturel liées à l'apprentissage et à la mémorisation (Dabladji 2016).

La sélection négative est une abstraction des mécanismes qui permettent aux systèmes immunitaires naturels de distinguer entre le soi (ses propres molécules) et le non soi (molécules étrangères). La sélection clonale est une abstraction des mécanismes de mémorisation des systèmes immunitaires (Nouicer 2014).

Chapitre 02 : les Métaheuristiques

Les étapes fondamentales de l'algorithme de clonage sont les suivantes:

- **Initialisation**

Générer aléatoirement un ensemble S de solution « anticorps ». La population S est divisée en deux composants, des anticorps à "mémoire" m qui représentent la solution et un ensemble r utilisé pour introduire de la diversité.

L'algorithme AIS est défini par (Delloul Ali 2015):

- Répéter tant qu'une condition prédéfinie n'est pas vérifiée
- Evaluation et sélection 1
- Calculer l'affinité entre tous les éléments de S avec l'ensemble des antigènes et sélectionner les anticorps qui ont la plus grande affinité.
- Cloner chaque anticorps sélectionné proportionnellement à son affinité, mettre les clones dans un ensemble C .
- Chaque clone de C subisse une mutation avec un degré inversement proportionnel à son affinité, Plus l'affinité est grande plus le taux de mutation est faible. Pour obtenir une population mature C^* qui répond mieux aux antigènes.
 - Sélectionner S_2 anticorps de C^* qui ont les plus grandes affinités pour obtenir un nouvel ensemble d'anticorps mémoire.
 - Combiner S_2 avec l'ensemble m , les anticorps générés aléatoirement et remplacer ceux qui ont la plus faible affinité pour obtenir l'ensemble des anticorps mémoire m .

Les anticorps non retenus dans m seront éliminés

Figure 2.8 : L'algorithme d'AIS

2.3 Conclusion

Dans ce chapitre, nous avons présenté quelques méthodes d'optimisation en s'appuyant sur les caractéristiques principales des métaheuristiques. Ces dernières sont très efficaces en optimisation difficile sans avoir besoin de modifier la structure de base de l'algorithme utilisé. Elles sont devenues très populaires grâce à leur simplicité d'emploi dans différents domaines. Il est à noter qu'une bonne performance nécessite souvent une formalisation adéquate du problème posé et une adaptation intelligente d'une métaheuristique. Malgré le succès remarquable de leur démarche, les métaheuristiques présentent des difficultés auxquelles est confronté l'utilisateur dans le cas d'un problème concret comme le choix d'une méthode efficace pour avoir une solution optimale et le réglage des paramètres qui peut être réalisable en théorie mais irréalisable en pratique.

Dans le chapitre suivant, nous présenterons l'optimisation de réseau de neurone par différentes approches PSO, GSA et PSOGSA afin de les injecter dans un processus de détection de changements basé sur la comparaison post-classification sur deux images satellitaires acquises à deux dates différentes.

Chapitre 03 :

Conception de l'approche proposée

Chapitre 03 : Conception de l'approche proposée

3.1 Introduction

D'une manière générale, l'utilisation de la télédétection dans le cadre des études de l'occupation des sols est assez récurrente. Son efficacité semble indéniable pour étudier l'évolution spatiotemporelle de phénomènes naturels, et la précision grandissante des images obtenues par les capteurs ne font qu'améliorer les résultats. Ainsi, l'occupation du sol peut non seulement être observée, mais elle peut surtout être extraite grâce à différents traitements (classification) basés sur la réponse spectrale des pixels.

Ce chapitre décrit l'approche proposée dans notre travail, il est scindé en deux parties. La première partie consiste à intégrer trois classifications neuronales MLP optimisées par PSO, GSA et PSO-GSA à la place de la rétro propagation du gradient pour minimiser la fonction d'erreur. La seconde partie est consacrée à la détection de changements avec la comparaison post classification.

3.2 Réseaux de neurones MLP

Un réseau de neurones multicouches est une extension du célèbre Perceptron, avec une ou plusieurs couches intermédiaires appelées "couche cachées". Ce sont les réseaux de neurone les plus connus.

Un tel réseau est présenté par un ensemble de neurones interconnectés entre eux de telle sorte que l'information circule des entrées vers les sorties.

La valeur de la sortie s'obtient en propageant les calculs de gauche vers la droite, avec éventuellement des connexions directes (Ramchoun et al. 2016).

3.2.1 Le fonctionnement du réseau MLP

En général, les neurones du Perceptron multicouches sont animés par une fonction d'activation non linéaire.

Chapitre 03 : Conception de l'approche proposée

Une des fonctions d'activation la plus utilisée généralement est la fonction sigmoïde définie comme suit (Msaaf and Belmajdoub 2015) :

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.1)$$

La figure 3.1 montre un MLP avec des couches (une entrée, une cachée et une couche de sortie), où le nombre de neurone de la couche d'entrée est égal à n , le nombre de neurone de la couche cachés est égal à h et le nombre de neurone de la couche de sortie est m .

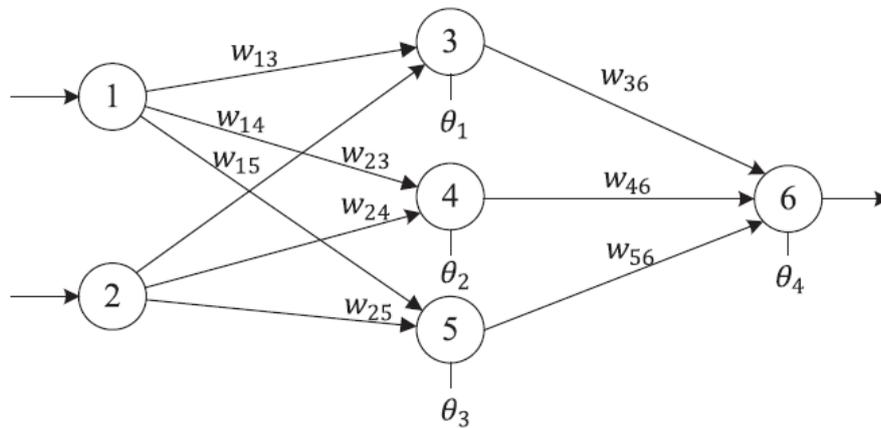


Figure 3.1 : MLP avec une structure 2-3-1.

À chaque itération d'apprentissage, la sortie de chaque neurone de la couche cachée est calculée comme suit:

$$f(s_j) = \frac{1}{1 + \exp(-s_j)} \quad (3.2)$$

$$s_j = \left(\sum_{i=1}^n w_{ij} \cdot x_i - \theta_j \right) \quad (3.3)$$

Où w_{ij} est le poids de connexion du i ème neurone de la couche d'entrée au j ème neurone de la couche cachée, θ_j est le biais (seuil) du j ème neurone caché, et x_i est la i ème entrée. Après avoir calculé les sorties des neurones de la couche cachée, la sortie finale peut être définie comme suit:

$$o_k = \sum_{j=1}^h w_{kj} \cdot f(s_j) - \theta_k \quad k = 1, 2, \dots, m \quad (3.4)$$

Chapitre 03 : Conception de l'approche proposée

Où w_{kj} est le poids de connexion du j ème neurone de la couche cachée au k ème neurone de la couche sortie et h_k est le biais (seuil) du k ème nœud de sortie.

Finalement, l'erreur d'apprentissage E (fonction de fitness) est calculée comme suit:

$$E_k = \sum_{i=1}^m (o_i^k - d_i^k)^2 \quad (3.4)$$

$$E = \sum_{k=1}^q \frac{E_k}{q} \quad (3.5)$$

Où q est le nombre d'échantillons d'apprentissage, d_i^k est la sortie désirée de la i ème unité d'entrée lorsque le k ème échantillon d'apprentissage est utilisé, et O_i^k est la sortie calculée de la i ème unité d'entrée lorsque le k ème échantillon d'apprentissage est utilisé.

Par conséquent, la fonction de fitness du i ème échantillon d'entraînement peut être définie comme suit (Gegout and Rossi 1994):

$$fitness(x_i) = E(x_i) \quad (3.6)$$

3.2.2 L'apprentissage

L'apprentissage dans le contexte des réseaux de neurones, est le processus de modification des poids de connexions (y compris les biais), afin d'adapter le traitement effectué par le réseau à une tâche particulière.

Dans l'apprentissage supervisé, un superviseur (ou expert humain) fournit une valeur ou un vecteur de sortie (appelé cible ou sortie désirée), que le réseau de neurones doit associer à un vecteur d'entrée.

L'apprentissage consiste dans ce cas à ajuster les paramètres du réseau afin de minimiser l'erreur entre la sortie désirée et la sortie réelle du réseau (Souissi 2020).

Chapitre 03 : Conception de l'approche proposée

3.2.3 Algorithme de rétro propagation du gradient

L'algorithme de la rétro propagation est un algorithme de gradient itératif conçu pour minimiser l'erreur quadratique entre la sortie obtenue d'un réseau multicouche et la sortie désirée.

Pour définir l'erreur sur chaque couche du perceptron. On doit calculer l'erreur de la dernière couche qui est effectivement l'erreur du réseau, et pour chaque couche cachée, les erreurs sont calculées à partir des erreurs de la couche suivante. Pour chaque neurone l'erreur est la somme des erreurs de chaque neurone de la couche suivante, pondérée par le poids qui le lie au neurone dont on calcule l'erreur et par la dérivée de la fonction d'activation. Pour cette raison cet algorithme est appelé rétro propagation de l'erreur (Zidane 2018).

3.2.4 L'optimisation du réseau de neurones MLP

L'apprentissage des poids et biais d'un réseau de neurones, est généralement obtenu en minimisant une fonction d'erreur. Cette fonction d'erreur est calculée à l'aide d'un groupe d'éléments d'apprentissage, pour lesquels les entrées ainsi que les sorties espérées sont connues. La plupart des méthodes d'apprentissage, telle que la rétro-propagation du gradient, ainsi que les algorithmes de gradients conjugués, sont basées sur la descente du gradient. Ces méthodes ont obtenu de grands succès dans de nombreuses applications. Cependant, un des problèmes fréquemment rencontré lors de l'apprentissage de réseaux de neurones, est la convergence vers des optima locaux. A la fin du processus d'itération, on n'obtient donc pas l'optimum global de la fonction d'erreur, mais un de ses optima locaux (Sabry et al 2015) (Tounsi 2017) (Aljarah et al. 2019).

Chapitre 03 : Conception de l'approche proposée

Une solution proposée pour résoudre ce problème, est l'utilisation des métaheuristiques tels que : PSO (l'optimisation par essaim de particules), GSA (l'algorithme de recherche gravitationnelle) et PSOGSA (l'hybridation de l'optimisation par essaim de particules et l'algorithme de recherche gravitationnelle) pour effectuer cet apprentissage.

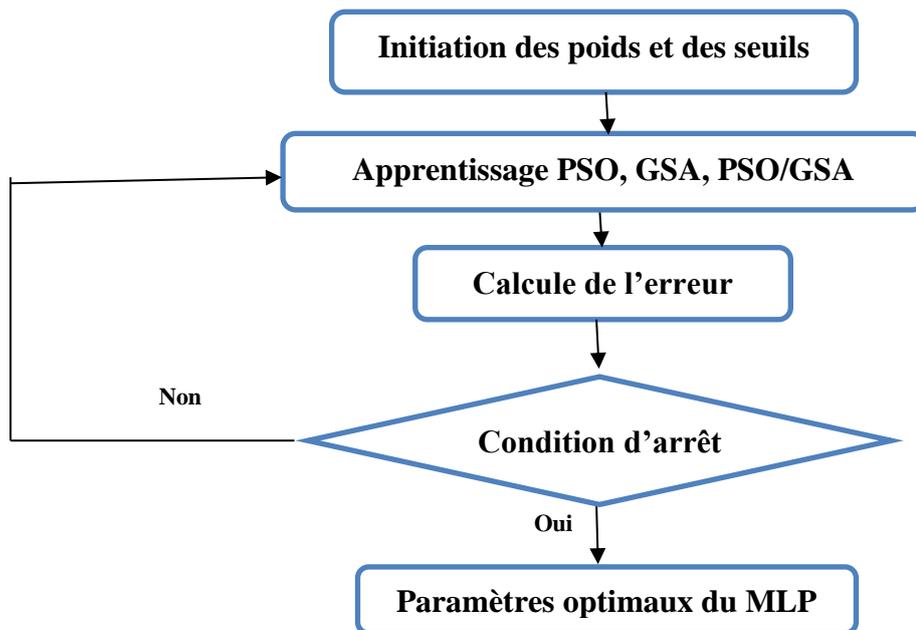


Figure 3.2 : Hybridation du MLP et les algorithmes méta heuristiques

3.2.4.1 L'optimisation du réseau de neurones MLP par PSO

Dans cette section, On utilise le PSO pour optimiser le MLP afin de trouver les poids et les biais optimaux.

La population initiale de l'algorithme PSO est constituée d'un nombre des particules, ou chaque particule représente un poids et biais du réseau, et chaque population représente une configuration complète du réseau. Les populations sont stockées sous forme de deux matrices, chaque matrice détermine l'ensemble des poids et biais de notre réseau, alors que chaque particule contient deux matrices (Mirjalili et al 2012) (Soon et al. 2018).

Chapitre 03 : Conception de l'approche proposée

Avec cette stratégie de codage pour MLP, le décodage est facile à exécuter. Dans le processus d'apprentissage de MLP, ce type de stratégie de codage est souvent adopté.

Au début, les poids et les biais sont sélectionnés au hasard dans un intervalle de 0 à 1, ensuite, pour chaque itération la fonction d'activation de chaque neurone est calculée (Bhattacharjee and Pant 2019).

Les processus de calcul du MLP/PSO sont illustrés dans la figure 3.3. (Carvalho and Ludermir 2006) (Huang and Chou 2019)

1. Sélectionner les paramètres initiaux du PSO, y compris la taille de population, les itérations maximales, la vitesse et la position initiales des particules sont sélectionnés au hasard dans un intervalle de 0 à 1. etc.
2. Calculez la sortie de la couche d'entrée vers la couche cachée, puis calculez la sortie de la couche cachée vers la couche de sortie. Ensuite, l'erreur d'apprentissage a été calculé comme fonction objective de PSO.
3. Calculer la valeur de fitness actuelle de chaque particule et la comparer avec la valeur de fitness de l'itération précédente. Si la valeur de fitness actuelle est meilleure, alors la position actuelle de la particule devient le nouveau Pbest.
4. Comparez les valeurs de fitness de chaque particule, et la plus petite valeur est la solution optimale de population Gbest.
5. La mise à jour de la vitesse et la position de chaque particule selon les équations suivantes :

$$V_i(k + 1) = W \cdot V_i(k) + C_1 \cdot r_1 (pbest_i - x_i(k)) + C_2 \cdot r_2 (gbest - x_i(k)) \quad (3.7)$$

$$x_{ij}(k + 1) = x_i(k) + V_i(k + 1) \quad (3.8)$$

Où

k: est le nombre d'itérations,

Chapitre 03 : Conception de l'approche proposée

w : est le coefficient d'inertie,

$V_i(k)$: est la vitesse courante de la particule i à l'itération k ,

$X_i(k)$: est la position actuelle de la particule i à l'itération k ,

C_1, C_2 : sont les coefficients d'accélération,

r_1, r_2 : sont des nombres aléatoires de distribution uniforme sur $[0,1]$.

$pbest_i$ est la solution optimale de la particule i à l'itération t , et $gbest_t$ est la solution optimale de la population.

6. Répétez les étapes 3 à 6 jusqu'à ce que le nombre d'itérations soit maximal.

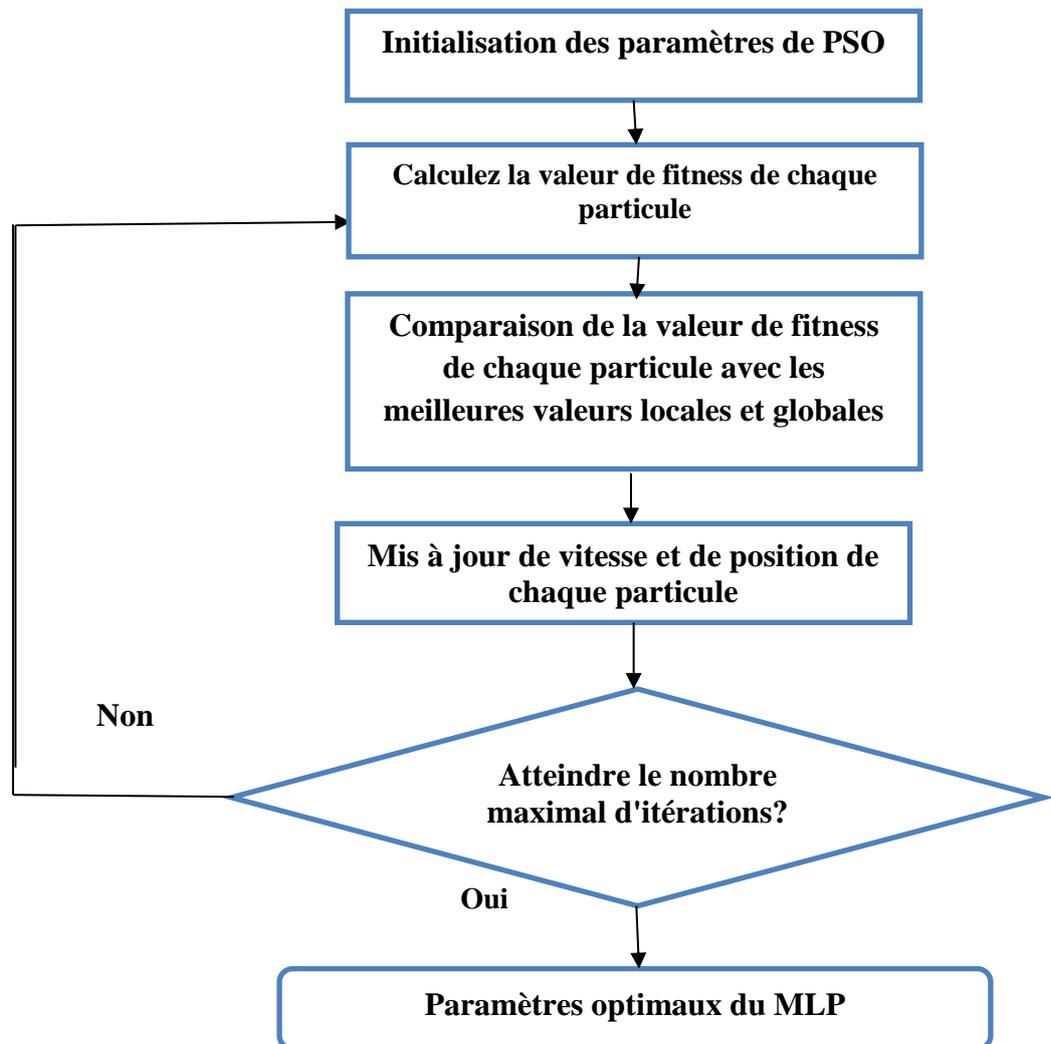


Figure 3.3 : Organigramme du modèle MLP/PSO.

Chapitre 03 : Conception de l'approche proposée

3.2.4.2 L'optimisation du réseau de neurones MLP par GSA

Dans cette section, le GSA a été utilisé pour optimiser le MLP afin de trouver les poids et les biais optimaux.

La population initiale de l'algorithme GSA est constituée d'un nombre des agents, ou chaque agent représente des poids et biais du réseau, et chaque population représente une configuration complète du réseau.

Les populations sont stockées sous forme de deux matrices, chaque matrice détermine l'ensemble des poids et biais de notre réseau, alors que chaque agent contient deux matrices (poids et biais) (Rather and Bala 2019a) (Rather and Bala 2020b).

Au début, les poids et les biais sont sélectionné au hasard dans un intervalle de 0 à 1, ensuite, pour chaque itération, calculée la fonction d'activation de chaque neurone. Les paramètres importants affectant les résultats GSA sont le constant α et le coefficient gravitationnel initial G_0 (A. Zhang et al. 2019).

Après la sélection des paramètres initiaux du GSA (Huang and Chou 2019).

1. Calculez la sortie de la couche d'entrée vers la couche cachée, puis calculez la sortie de la couche cachée vers la couche de sortie. La sortie résultante est le résultat de classification calculé par MLP.

2. Calculez la valeur de fitness actuelle de chaque agent, et définir le best(t) et le worst(t).

$$worst(t) = \min_{j \in (1,2,\dots,N)} fit_j(t) \quad (3.9)$$

$$best(t) = \max_{j \in (1,2,\dots,N)} fit_j(t) \quad (3.10)$$

Avec :

$fit_i(t)$: représente la valeur de la fonction objective de l'objet i à l'instant t

3. Mis à jour de constant de gravité $G(t)$.

$$G(t) = G_0 + \exp(-\alpha \times \frac{iter}{maxiter}) \quad (3.11)$$

Où G_0 et α sont des constantes.

Chapitre 03 : Conception de l'approche proposée

4. Calculez la masse $M_i(t)$ de chaque agent, puis déterminer sa force gravitationnelle $F_i^d(t)$.

$$m_i(t) = \frac{fit_i(t) - worst(t)}{best(t) - worst(t)} \quad (3.12)$$

$$M_i(t) = \frac{m_i(t)}{\sum_{j=1}^N m_j(t)} \quad (3.13)$$

La force de gravitation de j qu'influe sur i est donnée par :

$$F_{ij}^d(t) = G(t) \frac{M_{pi}(t) \times M_{aj}(t)}{R_{ij}(t) + \varepsilon} (x_j^d(t) - x_i^d(t)) \quad (3.14)$$

Avec :

Maj : est la masse de gravité active liée à l'agent j

Mpi : est la masse de gravité passive liée à l'agent i

G(t) : constante de gravité à l'instant t , ε : petit constant.

$$R_{ij}(t) = \|x_i(t) - x_j(t)\|_2 \quad (3.15)$$

$R_{ij}(t)$ est la distance euclidienne entre l'objet i et l'objet j

La force totale qui agit sur l'agent i dans la dimension d est donnée par :

$$F_i^d(t) = \sum_{i=1}^N rand \ F_i^d(t) \quad (3.16)$$

Avec $rand_j$ est un nombre aléatoire entre 0 et 1.

5. Calculez l'accélération $a_i^d(t)$.

$$a_i^d(t) = \frac{F_i^d(t)}{M_{ii}(t)} \quad (3.17)$$

Avec M_{ii} est l'inertie de l' i^{em} objet

6. Mis à jour de la vitesse et la position des agents.

$$v_i^d(t+1) = rand_i \times v_i^d(t) + a_i^d(t) \quad (3.18)$$

Chapitre 03 : Conception de l'approche proposée

$$x_i^d(t + 1) = x_i^d(t) + v_i^d(t + 1) \quad (3.19)$$

7. Répétez l'étape 1 à 6 jusqu'à ce que le nombre d'itérations soit de maximal.

Enfin, lorsque le nombre d'itérations maximal sont arrivés, l'apprentissage par GSA s'est arrêté (Sheikhan and Jadidi 2014) (Han, Xiong, and Duan 2015).

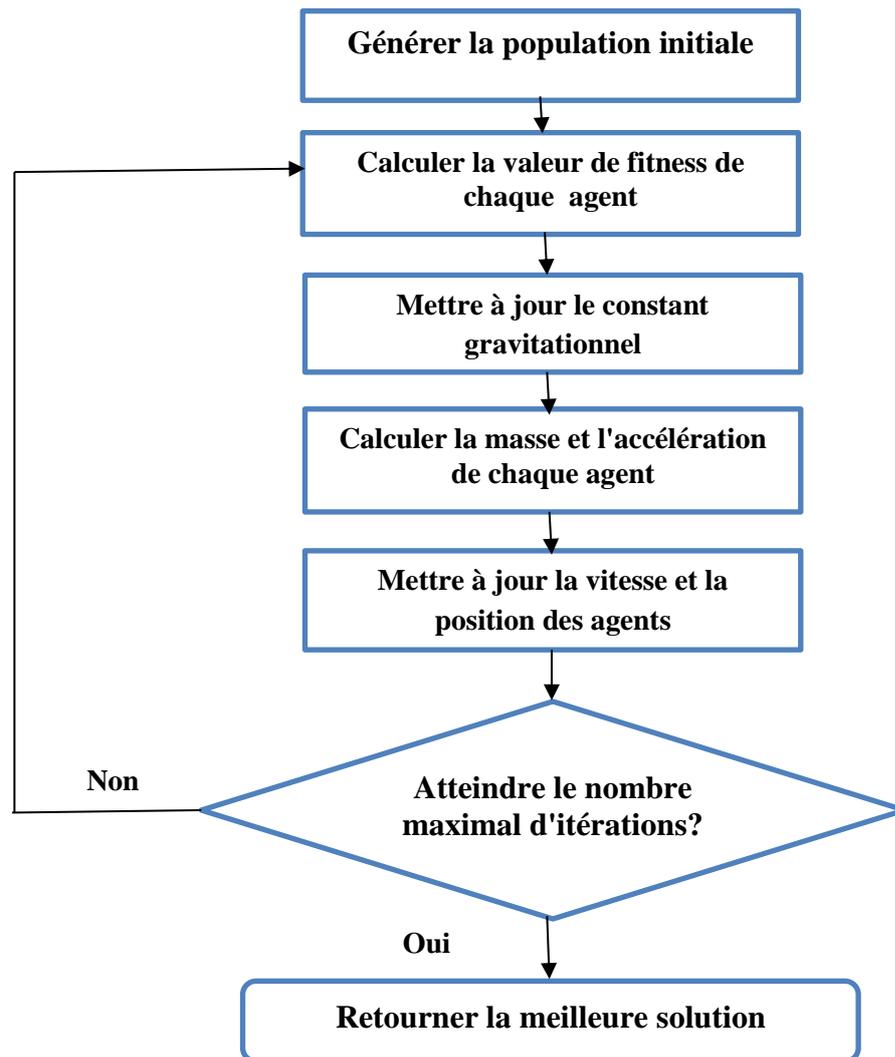


Figure 3.4 : Étapes générales de l'algorithme de recherche gravitationnelle

Chapitre 03 : Conception de l'approche proposée

3.2.4.3 L'optimisation du réseau de neurones MLP par PSO GSA

Dans cette section, l'hybridation PSO GSA a été utilisée comme fonction d'apprentissage de MLP afin de trouver les poids et les biais optimaux.

PSO GSA intègre la fonctionnalité d'échange d'informations de PSO avec la capacité de recherche locale de GSA;

La population initiale de l'algorithme PSO GSA est constituée d'un nombre des particules, ou chaque particule représente un poids et biais du réseau, et chaque population représente une configuration complète du réseau. Les populations sont stockées sous forme de deux matrices (particules), chaque matrice détermine l'ensemble des poids et biais de notre réseau (Rather and Bala 2020a) (Huang and Chou 2019).

Au début, les poids et les biais sont sélectionné au hasard dans un intervalle de 0 à 1, ensuite, la fonction d'activation de chaque neurone est calculée pour chaque l'itération.

1. Sélectionner les paramètres initiaux du PSO GSA et déterminez aléatoirement la vitesse et la position des particules, avec des valeurs allant de 0 à 1.
2. Calculez la sortie de la couche d'entrée vers la couche cachée, puis calculez la sortie de la couche cachée vers la couche de sortie. Ensuite, l'erreur d'apprentissage a été calculé comme fonction objective de PSO GSA.
3. Calculer la valeur de fitness actuelle de chaque particule et la comparer avec la valeur de fitness de l'itération précédente. Si la valeur de fitness actuelle est meilleure, alors la position actuelle de la particule devient le nouveau Pbest.
4. Comparez les valeurs de fitness de chaque particule, et la plus petite valeur est la solution optimale de population Gbest
5. Déterminez le worst (t) et le best (t) en utilisant les équations (3.9) et (3.10) respectivement.

Chapitre 03 : Conception de l'approche proposée

6. Calculez la masse $M_i(t)$ de chaque agent, puis déterminer la force gravitationnelle de de particule $F_{ij}^d(t)$ en utilisant l'équation (3.16). Ensuite, calculez le constant de gravité et l'accélération par les équations (3.11) et (3.17) respectivement.

7. Mis à jour de la vitesse et la position des particules par :

$$v_i(t+1) = w v_i(t) + c_1 \times rand \times a_i(t) + c_2 \times rand \times (gbest - x_i(t)) \quad (3.20)$$

$$x_i^d(t+1) = x_i^d(t) + v_i^d(t+1) \quad (3.21)$$

Où

w: est le coefficient d'inertie,

$V_i(t)$: est la vitesse courante de la particule i à l'itération t,

$X_i(t)$: est la position actuelle de la particule i à l'itération t,

C_1, C_2 : sont les coefficients d'accélération,

rand: est le nombre aléatoire de distribution uniforme sur [0,1].

$pbest_i$ est la solution optimale de la particule i à l'itération t, et $gbest$ est la solution optimale de la population.

8. Répétez l'étape 3 à 7 jusqu'à ce que le nombre d'itérations soit de maximal.

Enfin, lorsque le nombre d'itérations maximal sont arrivés, l'apprentissage par PSO-GSA s'est arrêté (Rather and Bala 2019c).

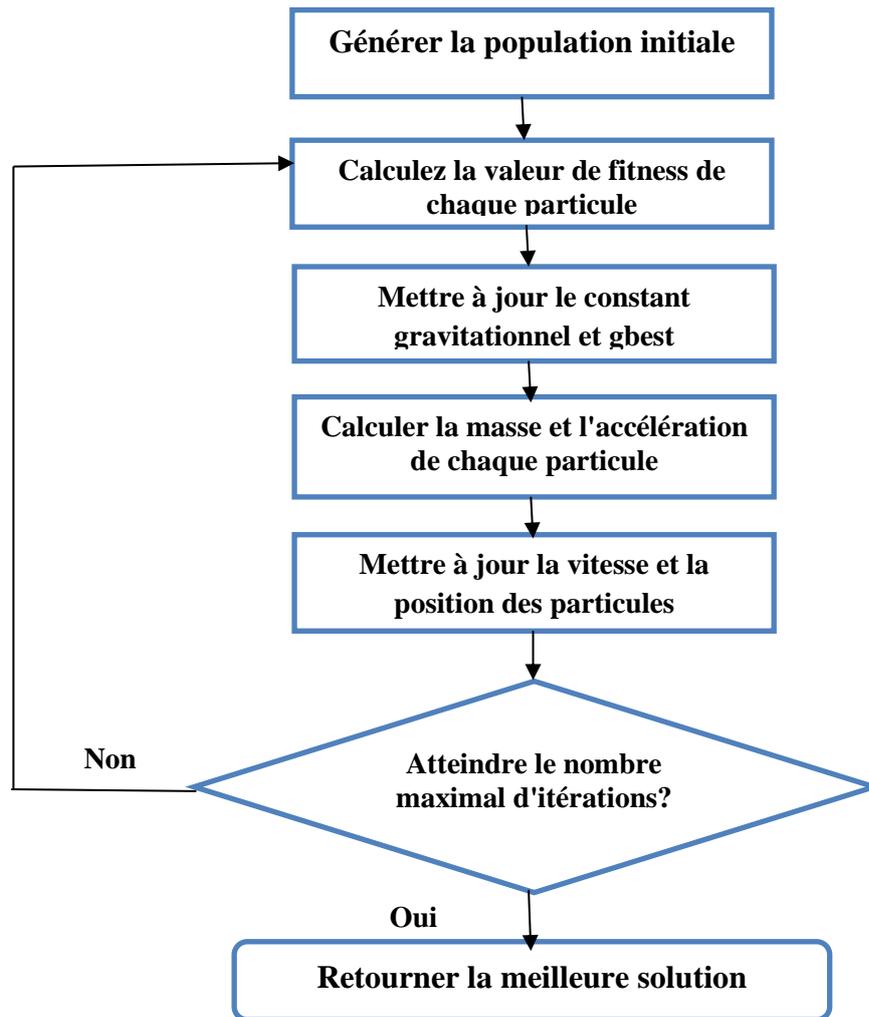


Figure 3.5 : Étapes de l'algorithme PSO-GSA

3.3 La détection de changement

L'analyse de détection des changements de la surface de la terre est un sujet très actif en raison de la préoccupation concernant les conséquences des changements mondiaux et locaux (Y. Zhang and Zhao 2020).

Les changements d'occupation des sols sont le produit de la combinaison de très nombreuses interactions entre la sphère anthropique et l'environnement. La détection des changements est le processus d'identification et quantification des différences temporelles dans l'état d'un objet ou d'un phénomène existant sur la surface de la terre en l'observant à des dates différentes (Riffi and Fizazi 2012) (Mouissa et al. 2018).

Chapitre 03 : Conception de l'approche proposée

Généralement, l'analyse du changement est une comparaison spatiale, spectrale, thématique et temporelle de deux images satellitaires prises à des dates différentes, ou d'une image satellitaire et une carte numérique, ou de deux ou plus couvertures des terres de la même zone géographique produites à partir des données de télédétection qui sont prises à des moments différents (Sakurada and Okatani 2015).

La figure ci-dessous représente un exemple de détection des changements:

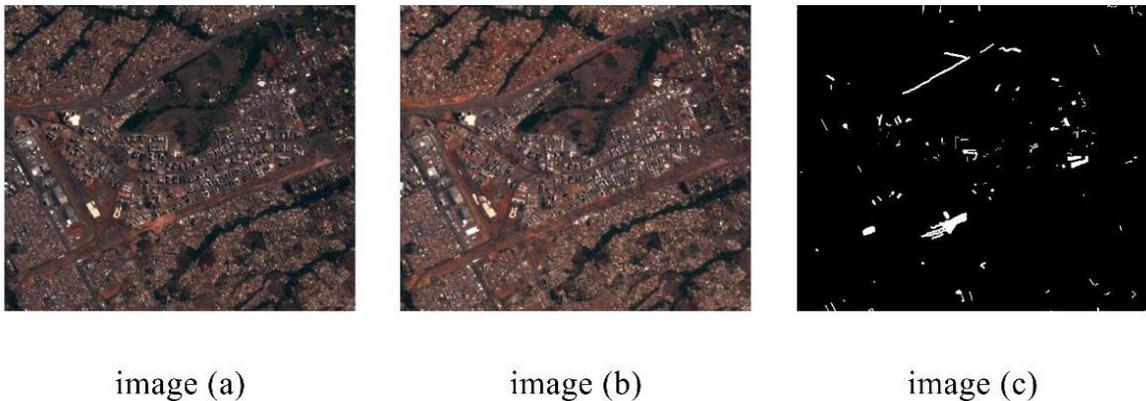


Figure 3.6 : Exemple de détection de changement.

3.3.1 Méthodes de détection des changements

Plusieurs auteurs ont publié des évaluations des méthodes de détection de changements, par exemple (Singh 1989) (Lu et al. 2004a) et (Asokan and Anitha 2019). Fondamentalement, les techniques de détection des changements ont été divisées en plusieurs catégories (S. Liu et al. 2019) (Tableau 3.1).

Il y a plusieurs méthodes pour détecter les changements d'occupation de sols et elles seront analysées et discutées dans la section suivante.

Chapitre 03 : Conception de l'approche proposée

Catégorie	Techniques
Algébrique	<ul style="list-style-type: none"> - Différence d'images -Régression d'images (Luppino et al. 2018) -Différence d'indices de végétation -Division d'images -Soustraction (différence) d'images de base -Analyse par vecteur de changement
Transformations	<ul style="list-style-type: none"> -Analyse en composantes principales (ACP) (de Estibaliz Martinez et al 2019). -Transformation Tasseled Cap -Gramm-Schmidt
Classifications	<ul style="list-style-type: none"> -Comparaison de post-classification -Analyse spectrale temporelle -Détection du maximum de probabilité -Détection de changements non dirigée -Détection de changements hybride -Réseaux de neurones (Radke et al. 2005)
Méthodes avancées	<ul style="list-style-type: none"> -Modèle de réflectance de Li-Strahler -Modèles de mixage spectral (Lu et al 2004b) -Méthode de paramètres biophysiques
Approche de SIG	<ul style="list-style-type: none"> -Méthode d'intégration de SIG et de données de télédétection
Analyse visuelle	<ul style="list-style-type: none"> -Interprétation visuelle d'image (Nemmour 2003)
Autres techniques	<ul style="list-style-type: none"> -Mesure de dépendance spatiale -Système d'observation basée sur la connaissance -Méthode de génération de superficie (area production method) -Combinaison de trois indicateurs : indices de végétation, température de surface et structure spatiale -Courbe de changements -Modèles linéaires généralisés

Chapitre 03 : Conception de l'approche proposée

	<ul style="list-style-type: none">-Approche basée sur le théorème de courbe-Approche basée sur la structure-Méthode basée sur la statistique spatiale
--	---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

Tableau 3.1 : Techniques de détection de changement.

3.3.1.1 Méthodes algébriques

La méthode algébrique comprend des méthodes simples impliquant la soustraction, la division, la régression d'images, la différence de l'indice de végétation, etc. entre les valeurs numériques (spectrales) de deux images bi-temporelles couvrant une même région (Canty 2014).

L'opération mathématique est appliquée à chacun des pixels se superposant afin de créer une nouvelle image. La réponse est binaire (changement/pas de changement) et déterminée par un seuil judicieusement établi par l'utilisateur. Ce seuil sert à délimiter la présence et l'absence de changements. Ces méthodes sont couramment utilisées en télédétection à cause de leur rapidité d'exécution et la simplicité de mise en œuvre.

L'inconvénient des méthodes algébriques est :

- Sensibilité à la qualité des corrections géométriques et radiométriques.
- Analyse délicate de l'image accentuée.
- Aucune information sur la nature des changements.

A) Différence d'images

La différenciation d'image est une soustraction des valeurs radiométriques des images. La soustraction donne une nouvelle image comprenant de l'information pour les changements recherchés et elle sera analysée par les techniques numériques ou visuelles.

Chapitre 03 : Conception de l'approche proposée

Cette méthode est très simple et donc souvent utilisée. Par contre, elle présente des limites : la difficulté de la séparation des pixels changés et non changés; la grande sensibilité à la qualité de la superposition des images et la difficulté d'obtention de la nature des changements (Dorais 2011) (Jeanson 2015).

B) Division d'images

La méthode de division d'images consiste à diviser deux bandes spectrales identiques des images considérées pour avoir une nouvelle image de changements. Cette méthode présente les mêmes limites que la méthode de différenciation (Hussain et al. 2013).

C) Analyse par vecteur de changement

La méthode d'analyse de vecteur de changements se base sur l'espace (ou le diagramme schématique) de n variables spectrales qui forment un vecteur de changements. L'amplitude de ce vecteur signifie l'importance des changements, sa direction contient de l'information sur les types de changements, ce qui est l'avantage de cette méthode. Pourtant, en pratique, cette dernière est difficile à réaliser, car les vecteurs de changements sont nombreux et leur analyse en vue de déterminer les types de changements est complexe.

En plus, elle est sensible à l'erreur géométrique et à la différence radiométrique des images d'origine (Mas 2000) (Polykretis, Grillakis, and Alexakis 2020).

D) Indice Différentiel de Végétation

Ils sont très utilisés d'une part, pour identifier et suivre la dynamique de la végétation. Le principal indice utilisé dans l'analyse des images satellitaires multi spectrales est l'indice de végétation normalisé (NDVI) qui va traduire la densité du feuillage et la proportion de sol effectivement couverte par la végétation.

Chapitre 03 : Conception de l'approche proposée

Les réflectances dans le proche infrarouge augmentent avec la présence de la végétation, tandis que celles dans le rouge diminuent (pic d'absorption de la chlorophylle) (Gandhi et al. 2015) (Dissanayake 2020).

L'indice NDVI, (Normalised Difference of Vegetation) Index est un variable calculée à partir des bandes rouges et proche infrarouge qui permet de mieux cerner la végétation ainsi que différentes particularités s'y rattachant.

Il est défini de la manière suivante :

$$NDVI = (PIR - R) / (PIR + R) \quad (3.20)$$

PIR = Réflectance dans le canal proche infrarouge et R = Réflectance dans le canal rouge.

3.3.1.2 Méthodes de transformation

Ces méthodes sont plus complexes que les méthodes algébriques mais encore assez simples. Elles peuvent utiliser plusieurs bandes à la fois pour la détection de changements tout en réduisant les informations redondantes entre les bandes. Il s'agit d'une vision systématique de l'analyse statistique des propriétés des variables, il s'agit essentiellement d'une transcription de l'information qui peut dans certain cas mener à une représentation qui soit plus propice à permettre d'identifier certains types d'information que ce qui était possible en utilisant les variables de base.

Cependant, il est difficile d'interpréter et étiqueter les informations de changement sur les images puisque ces méthodes ne peuvent pas fournir des matrices de changement détaillées et elles nécessitent la sélection de seuils pour identifier les zones changées. Par conséquent, l'analyste doit posséder une bonne connaissance pour le choix des composantes et des seuils (Lu et al. 2004a).

Chapitre 03 : Conception de l'approche proposée

A) Transformation de Tasseled Cap

La méthode de la transformation de Tasseled Cap calcule les indices de verdure, de luminance du sol et d'humidité (Minu and Shetty 2015). Ces derniers sont soustraits pour produire une image de changements et ils sont utiles en milieux agricole, forestier ou urbain. Donc, cette méthode peut aider les autres méthodes en réduisant leurs inconvénients. Comme pour les techniques de la catégorie Algèbre, ces méthodes ne permettent pas de créer une matrice de changements détaillée renseignant sur la nature des changements (Chen et al. 2019).

3.3.1.3 Méthodes de classification

Cette catégorie est basée sur le traitement d'images déjà classifiées (ex : carte thématique). Contrairement aux techniques précédentes, celles-ci permettent d'identifier la détection du changement par le biais d'une table de contingence mettant en relation les couvertures de sol de deux années différentes (R. Liu et al 2019). Cependant, les résultats de ces méthodes dépendent entièrement de la qualité des classifications et propagent les erreurs de celles-ci dans la détection de changements. L'obtention d'une précision acceptable peut s'avérer difficile, puisqu'un grand nombre de sites tests, de même que l'intégration de différentes sources d'information (indices de végétation, textures, etc.) sont souvent nécessaires.

Ces techniques ont l'avantage de diminuer l'impact des différences radiométriques entre les images, puisqu'elles comparent des images déjà classifiées.

La plus simple et la plus utilisée de ces méthodes est la comparaison post-classification, qui compare deux classifications thématiques aux temps t_1 et t_2 produites indépendamment l'une de l'autre.

Chapitre 03 : Conception de l'approche proposée

A) Comparaison de post-classification

Les méthodes post-classificatoires comparent des classifications indépendantes des images de différentes dates. Elles sont souvent utilisées à cause de leur simplicité et du fait qu'elles rendent compte de la nature des changements. Cependant, elles donnent des résultats moyens, car la qualité des résultats dépend de l'exactitude de chacune des classifications et de la superposition des images. De plus, ces méthodes ont tendance de surestimer les changements (Wan, Xiang, and You 2019). Pour éliminer ces erreurs, certains auteurs ont combiné ces méthodes avec d'autres, par exemple avec la soustraction (ou la différenciation) d'images, l'analyse de texture, l'analyse de vecteurs de changements et la logique floue.

D'une part, les méthodes reposant sur la comparaison post classification peuvent reposer sur l'utilisation d'images ayant des résolutions ou des types différents (Jiang et al. 2020). Ceci est possible, car les liaisons entre les classes découvertes par les différentes étapes de classification et de traitement peuvent être définies en utilisant des règles de correspondance créées spécifiquement pour résoudre un cas précis. Par contre, la modélisation et la séparation des classes doivent être réalisées au préalable, indépendamment pour chaque image de la série. Ceci ne pose pas de problème en soi, mais il faut tenir compte du fait que les modèles de classification seront probablement différents et que ce n'est pas toujours une tâche aisée d'obtenir les mêmes classes conceptuelles à partir de deux jeux de données indépendants classés séparément (Panuju et al 2019).

Dans notre travail, l'accent est mis sur la comparaison post-classification pour avoir la carte de changement.

Chapitre 03 : Conception de l'approche proposée

3.3.1.4 Méthodes avancées

Ces méthodes sont appliquées pour la détection de changement des paramètres biophysiques, en particulier la végétation. Bien que ces méthodes fournissent des informations précises et détaillées sur la nature des changements, elles sont complexes et elles exigent l'estimation des paramètres biophysiques ainsi que l'identification de composantes spectrales homogènes (Albetis de la Cruz 2018).

3.3.1.5 Approches de Systèmes d'Information Géographique (SIG)

Les méthodes basées sur système d'informatique géographique (SIG) incluent l'intégration de SIG et la télédétection et le pur SIG.

Cette méthode permet de superposer directement les différentes sources de données en détectant les changements: des données du SIG sur l'image ou seulement des diverses données actuelles et passées du SIG (carte de l'utilisation des terres, carte topographie, etc.). Elle permet aussi de transférer les images traitées dans un système de base de données SIG. La plupart des applications de cette méthode se concentrent sur le changement de la zone urbaine vu qu'elle donne de meilleurs résultats que les méthodes traditionnelles par rapport à la complexité du paysage urbain (Lu et al. 2004a).

Elles sont efficaces notamment pour le suivi de l'occupation du sol et de l'étalement des zones urbaines. Ces milieux étant complexes, l'incorporation des données multi-sources est souvent nécessaire. Néanmoins, ces méthodes sont assez complexes d'utilisation et l'hétérogénéité de la précision des données utilisées rend parfois difficile l'obtention de résultats de changements satisfaisants (Bensaid 2021).

Chapitre 03 : Conception de l'approche proposée

3.3.1.6 Méthodes d'interprétation visuelle

L'analyse visuelle consiste à photo-interpréter des composés d'images multi-temporelles et de numériser manuellement à l'écran les zones de changements. L'intérêt de cette méthode réside dans la mise à profit des connaissances et de l'expérience de l'analyste. De plus, l'œil humain peut distinguer très efficacement les changements de texture, de taille et de forme pour ensuite les associer à une information thématique (Nemmour 2003).

3.4 Schéma général de l'approche proposée

La figure 3.7 illustre l'organisation des étapes de traitements adoptée en vue d'une classification supervisée détection de changements. Rappelons que les algorithmes PSO (l'optimisation par essaim de particules), GSA (l'algorithme de recherche gravitationnelle) et PSOGSA (l'hybridation de l'optimisation par essaim de particules et l'algorithme de recherche gravitationnelle) ont été introduire dans l'apprentissage de réseau de neurone MLP.

Chapitre 03 : Conception de l'approche proposée

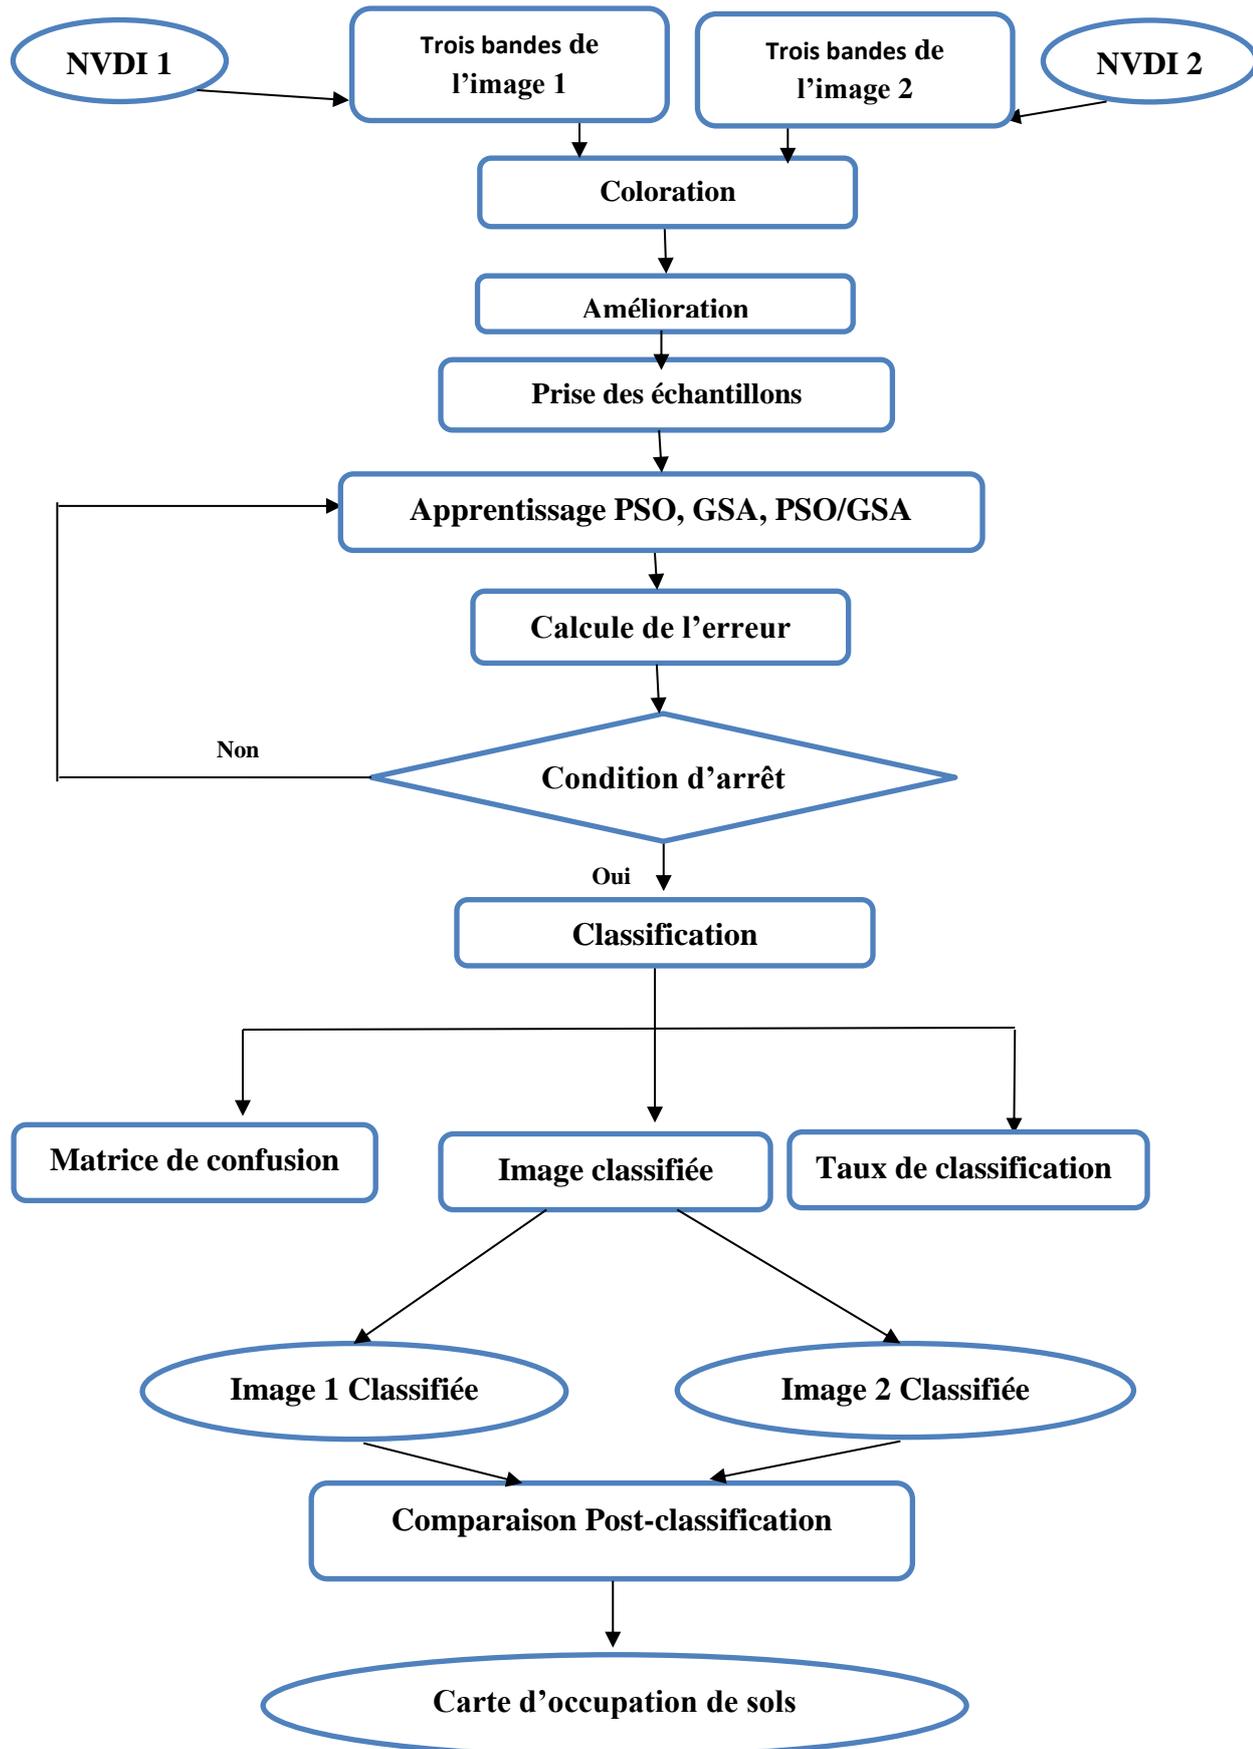


Figure 3.7 : Schéma du processus adopté

Chapitre 03 : Conception de l'approche proposée

La classification utilise les indices NDVI pour chaque image tout en combinant les indices aux cotés de canaux bruts de radiométrie. Les résultats de classification sont intégrés par la suite dans le processus de détection de changements (post-classification) pour obtenir la carte d'occupation de sols.

3.5 Conclusion

Dans ce chapitre, nous avons abordé dans sa première partie le principe et les techniques d'optimisation de réseau de neurone MLP par trois métaheuristiques cité précédemment. Aussi, on a présenté dans la deuxième partie les méthodes de détections de changements par la technique post-classification qui présente un intérêt considérable dans la détection de changement.

Dans ce qui suit, nous allons passer à l'implémentation des méthodes cités dans ce chapitre, ainsi que les résultats obtenus de notre processus de classification des images satellitaires.

Chapitre 04 :

Implémentation et Résultats

Chapitre 04 : Implémentation et résultats

4.1 Introduction

Dans ce chapitre, on aborde le module expérimentations et résultats, après avoir détailler le coté théorique des méthodologies utilisées dans les chapitres précédents.

Notre travail consiste à classer les différents pixels d'une image satellitaire en utilisant un réseau de neurone MLP (perceptron multi couche) optimisé par trois algorithmes PSO (l'optimisation par essaim de particules), GSA (l'algorithme de recherche gravitationnelle) et PSOGSA (l'hybridation de l'optimisation par essaim de particules et l'algorithme de recherche gravitationnelle) qui seront ensuite utilisées le résultat de classifiication dans le processus de détection de changements (post-classification).

La méthode s'appuie sur la classification multi-dates qui permet une meilleure discrimination des espaces Maquis par rapport aux autres objets présents sur les images satellitaires. Cette méthode vise à produire des cartes de changements qui facilitent l'appréciation des caractéristiques spatiales et temporelles.

4.2 Site d'étude

Les zones étudiées (Figure 4.1) sont connues par la diversité du terrain, la présence de plusieurs thèmes et les problèmes de confusion entre les différentes classes, ce qui représente des plates-formes idéales pour l'examen de l'efficacité de la démarche méthodologique utilisée et dont les caractéristiques relatives sont reportées dans le tableau 4.1.

Les procédures de notre classification ont été testées sur les données numérisées des images satellites Sentinel 2- L2A, de la région de Stidia nord de l'Algérie acquise le 27 Juillet 2019 de 400 x 400 pixels avec une résolution spatiale de 10 mètres.

La région de Stidia est une commune côtière de la wilaya de Mostaganem en Algérie, situé à 62 km d'Oran et à 14 km de Mostaganem.

Chapitre 04 : Implémentation et résultats

Pour la détection de changements nous utiliserons une image satellitaire de la région d'Oran, située à 400 km à l'ouest d'Alger, a été prise comme zone d'étude pour la variété des thèmes en présence (Eau, forêt, zones urbaines, Terres agricoles, etc.) et son relief relativement accidenté.



(a) : La zone de Stidia



(b) : La zone d'Oran.

Figure 4.1 : Les images satellitaires de site d'étude.

Chapitre 04 : Implémentation et résultats

Figure	Satellite	Résolution spatiale	Taille en pixels	Date d'acquisition
4.1. a	Sentinel 2-L2A	10 m	400x400	27 Juillet 2019

Tableau 4.1 : Caractéristiques des données utilisées (Figure 4.1.a).

4.3 But de l'application

Nous visons la détection des changements de l'occupation du sol sur la région d'Oran entre deux dates en utilisant la télédétection. Il s'agit donc d'identifier les changements versant à différentes dates à l'aide de classification d'images captées par des satellites d'observation de la Terre. De ces analyses, il résultera des images satellitaires transformées en cartes thématiques de l'occupation du sol pour différentes années et ensuite en cartes de changement durant la période observée. La démarche méthodologique de ce traitement se résume en une méthode de détection des changements en utilisant la comparaison post-classification. Cette méthode prend deux images de classification de la même scène prises à différents moments et identifie les différences entre elles pour montrer les transitions des classes.

Nous visons à améliorer la qualité d'images classifiées en utilisant des données additives telles que l'indice NDVI.

La classification utilise les indices NDVI pour chaque image tout en combinant les indices aux côtés de canaux bruts de radiométrie.

Dans notre travail, nous nous sommes intéressés à la classification supervisée par le réseau de neurone MLP (perceptron multicouche). Pour ce faire nous proposons trois approches méta heuristiques dans l'apprentissage : PSO, GSA et PSO-GSA.

Chapitre 04 : Implémentation et résultats

4.4 Données utilisées pour la classification

Nous avons téléchargé ces images gratuitement par le site landviewer¹ avec une taille d'image de 400 ×400 pixels.

Le processus de la classification est implémenté par un ordinateur portable Sony, doté d'un processeur Intel Core i5 de 2.67 Ghz, et d'une mémoire vive d'une capacité de 4 Go, sous le langage Matlab 2013b.

4.4.1 La coloration et l'amélioration

Après le chargement des images, nous appliquerons un traitement bien précis sur l'image qui est la coloration pour mieux interpréter l'image.

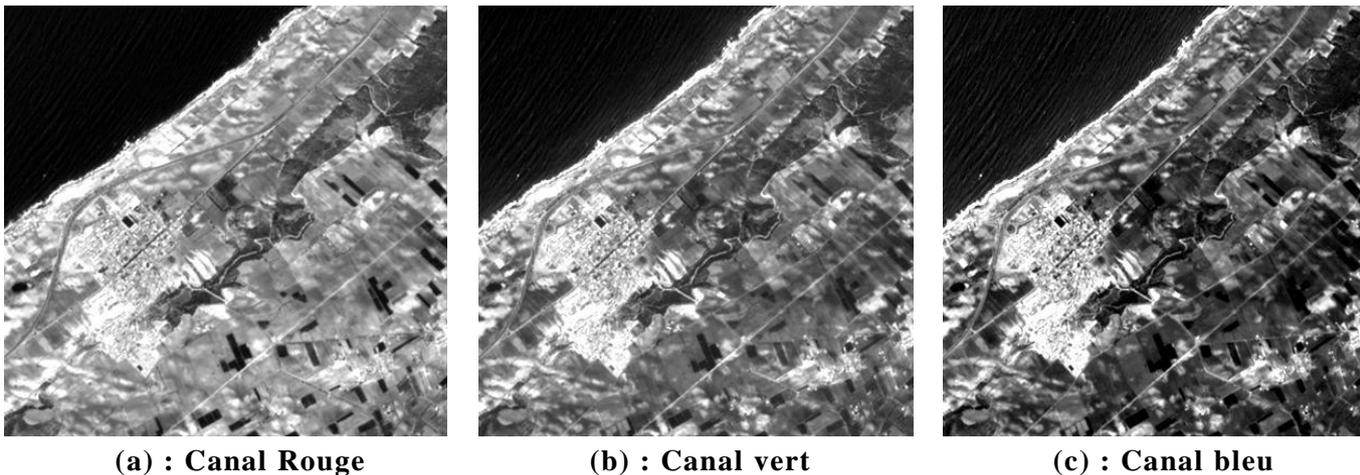


Figure 4.2 : Images satellitaires selon les trois canaux RGB (4, 3, 2).

Ensuite nous appliquons une amélioration, par un ensemble de coefficients bien définis, afin de faciliter les prises des échantillons.

¹ <https://eos.com/landviewer>

Chapitre 04 : Implémentation et résultats

4.4.2 L'échantillonnage

L'échantillonnage est la partie la plus importante dans toute application, elle nécessite l'apprentissage car les résultats y sont pondérés.

Les données d'apprentissage sont des pixels de chaque classe, choisis en utilisant des connaissances thématiques des classes présentes dans la zone à étudier, par conséquent la taille des échantillons est prise selon la nature de chaque classe.

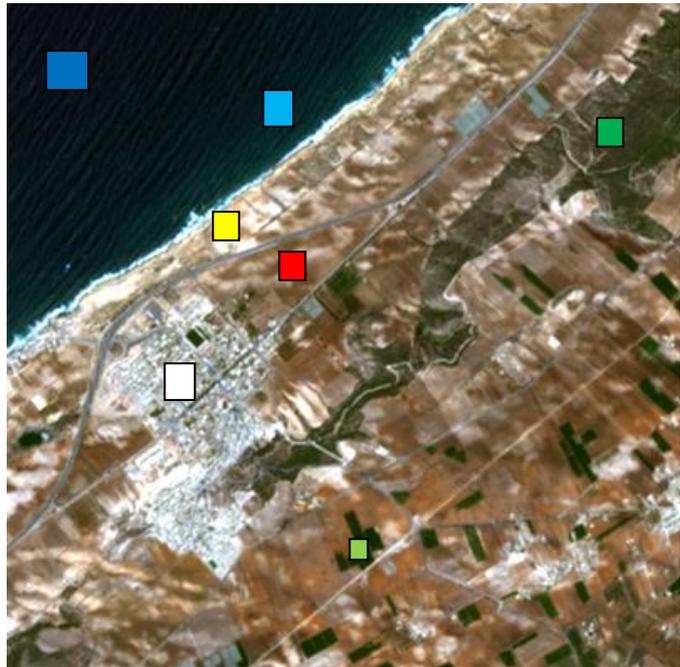


Figure 4.3: Image échantillonnée.

4.4.3 L'apprentissage

Dans notre travail nous nous sommes intéressés à la classification supervisée. Pour ce faire nous considérons l'optimisation de l'apprentissage du réseau de neurones MLP par les algorithmes tels que : PSO, GSA et PSO-GSA.

Dans ce bloc nous utilisons l'approche hybride proposée afin d'obtenir les meilleurs poids et biais. Le principe de l'approche proposée est de garder l'architecture du réseau MLP, ces fonctions de calcul d'erreur, puis introduire les algorithmes PSO, GSA et PSO-GSA dans l'apprentissage.

Chapitre 04 : Implémentation et résultats

Ces mécanismes sont appelés MLP/PSO, MLP/GSA et MLP/PSOGSA, respectivement. Cela signifie que la structure du MLP est fixe; PSO, GSA et PSOGSA trouvent une meilleure combinaison des poids et biais qui donnent l'erreur d'apprentissage minimale pour le MLP.

4.4.4 Classification

Dans cette partie, la classification supervisée par le réseau de neurone (perceptron multi couche) a été appliquée sur des images satellitaires en optimisant les poids et les biais initiaux par les algorithmes méta-heuristiques: PSO, GSA et l'hybridation PSO et GSA.

-Nombre de neurones de la couche cachée

L'inconvénient des réseaux à couches est le manque d'éléments théoriques permettant de relier d'une part le nombre de couches cachées et le nombre de neurones par couche et d'autre part le type et la complexité du problème à traiter. Il existe des équations empiriques pour déterminer le nombre maximal de neurones dans une couche cachée. La formule (4.1), nous montre une heuristique pour déterminer ce nombre.

$$N_c \leq 2.N_e + 2 \quad (4.1)$$

Où

N_e est le nombre d'entrées du MLP.

N_c est le nombre entier de neurones cachés.

Généralement pour déterminer le nombre neurones dans la couche cachée, le concepteur doit effectuer un grand nombre d'expériences. Par exemple, on fait varier la taille du réseau puis on effectue un apprentissage complet pour chaque taille et enfin on choisit la structure qui conduit aux meilleurs résultats.

Les meilleurs résultats sont ceux obtenue par une architecture à une seule couche cachée, car cette dernière nous permet d'obtenir les bons résultats en peu de temps et peu d'itération.

Chapitre 04 : Implémentation et résultats

Après avoir effectué plusieurs essais sur l'apprentissage du réseau de neurones en terme de variation de tous les paramètres qui caractérisent l'architecture du réseau, en particulier les fonctions d'activation et le nombre de couches cachés, nous sommes arrivés à fixer les paramètres suivants :

Nombre de neurone de la couche d'entrée	: 03
Nombre de couches cachées	: 01
Nombre de neurones de la couche cachée	: de 8 à 16.
Fonction de transfert	:Sigmoïde
Fonction coût	:Erreur Quadratique Moyenne(EQM)
Algorithmes d'apprentissages	: PSO, GSA, PSO/GSA
Nombre de classes en sortie	: 07

Lorsque le nombre d'itérations maximal atteint, l'algorithme d'apprentissage se termine.

4.4.4.1 Classification MLP/PSO

Dans la première étape, nous appliquons la méta-heuristique PSO à la classification par MLP de notre zone d'étude (Stidia).

Les paramètres de PSO sont fixés comme suit :

C1, C2 (Constantes personnels et sociales)	: 2
W_{\max} (Poids d'inertie maximal)	: 0.9
W_{\min} (Poids d'inertie minimal)	: 0.2
Nombre maximal d'itérations	: 5000
La taille de population	: de 10 à 50

Chapitre 04 : Implémentation et résultats

a- Résultats

Cette étape présente un problème principal qui est celui du choix de la taille de la population. Dans cet essai nous avons fixé le nombre de neurone de la couche cachée à 8 et nous avons fait varier la taille de la population de 10, 20, 30, 40 et 50. Ensuite, on calcule l'erreur et le taux d'apprentissage de la population.

08 neurones de la couche cachée

10	20	30	40	50
84,91%	89,12%	90,69%	89,55%	91,26%

Tableau 4.2 : Précisions globales obtenues par le classifieur MLP/PSO en variant de la taille de population.

08 neurones de la couche cachée

10	20	30	40	50
0.08565	0.02525	0.02167	0.02373	0.01479

Tableau 4.3: EQM obtenues par le classifieur MLP/PSO en variant de la taille de population.

On fonction du taux d'apprentissage (tableau 4.2), on remarque que l'initialisation (la taille de population est égal à 10) nous donne des précisions globales faibles, donc l'augmentation de la taille de populations influe directement sur les résultats obtenus, avec une architecture qui comporte 08 neurones dans la couche cachée on a obtenu les meilleurs taux (taux = 91,73%).

Chapitre 04 : Implémentation et résultats

C'est la même chose pour l'erreur quadratique moyenne (tableau 4.3), l'initialisation nous donne des erreurs très grandes qui signifient qu'il y a une grande distance entre les sorties désirées et les sorties calculées, on a obtenu une erreur minimale de 0.01479 dans la même architecture de réseau qui comporte 8 neurones et la taille de population=50.

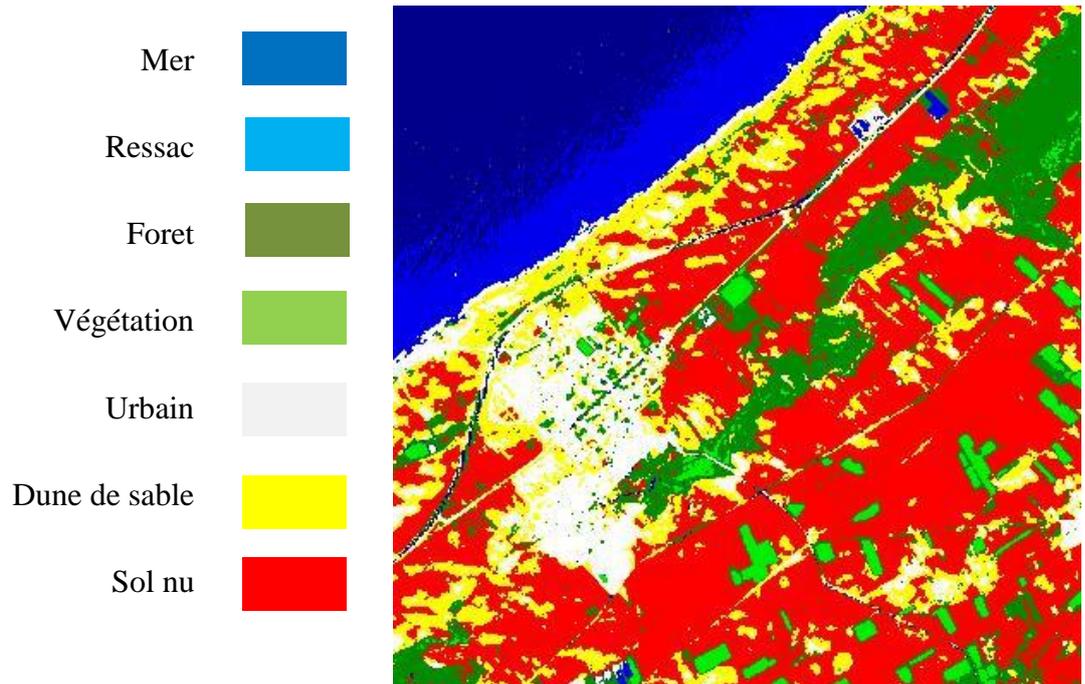


Figure 4.4 : Classification MLP/PSO avec la taille de population =50

Taux : 91.26%	Mer	Ressac	Urbain	Foret	Végétation	Sol nu	Dune de sable
non classés	0	0	0	0	0	0	0
Mer	100	0	0	0	0	0	0
Ressac	0	100	0	0	0	0	0
Urbain	0	0	94.88	0	0	0	23.85
Foret	0	0	0.63	87.85	0	0	0
Végétation	0	0	0	11.36	100	0	0
Sol nu	0	0	0	0.79	0	100	20
Dune de sable	0	0	4.49	0	0	0	56.15
Total	100	100	100	100	100	100	100

Tableau 4.4 : Matrice de confusion relative à la classification MLP/PSO

Chapitre 04 : Implémentation et résultats

A travers la matrice de confusion de l'image classée par MLP/PSO (tableau 4.4), on peut dire que presque la totalité des pixels affectés à ces classes ont été bien classés. Les faibles confusions constatées ne dépassent pas les 01 % pour la majorité des classes.

Les confusions les plus élevées ont été retrouvées pour les classes Urbain et Dune de sables (23.85%). La confusion entre les classes citées peut être expliquée par une réponse spectrale très proche.

4.4.4.2 Classification MLP/ GSA

Dans cette partie nous appliquons la méthode GSA à l'apprentissage de MLP pour la classification des images de télédétection.

Les paramètres de GSA sont fixés comme suit :

le coefficient gravitationnel initial G_0	: 1
Le constant α	: 20
La taille de population	: de 10 à 50
Le nombre maximal d'itérations	: 5000

a- Résultats

Afin de choisir la taille de la population convenable, on va appliquer notre approche MLP/GSA tout en variant la taille de population à 10, 20, 30, 40 et 50 avec le même nombre d'itérations et le nombre de neurone de la couche cachée de MLP/PSO.

Les résultats obtenus indiquent la précisions globales et l'erreur quadratique moyenne de chaque classification, et ils sont consignés respectivement dans le tableau 4.5 et 4.6.

Chapitre 04 : Implémentation et résultats

08 neurones de la couche cachée				
10	20	30	40	50
82.89%	84.56%	86.97%	85.37%	88.68%

Tableau 4.5 : Précisions globales obtenues par le classifieur MLP/GSA en variant la taille de population.

08 neurones de la couche cachée				
10	20	30	40	50
0.14296	0.09682	0.05029	0.06185	0.04478

Tableau 4.6 : EQM obtenues par le classifieur MLP/GSA en variant la taille de population.

A partir des résultats obtenus à partir des (tableau 4.5 et tableau 4.6), nous remarquons que plus la taille de la population est petite plus la diversité de la population s'affaiblie; dans le cas contraire (la taille de population est élevée) la précision globale augmente et on a obtenu une erreur minimale (EQM=0.04478). Cependant le meilleur résultat a été obtenu avec la taille de population=50 (Figure 4.5).

Chapitre 04 : Implémentation et résultats

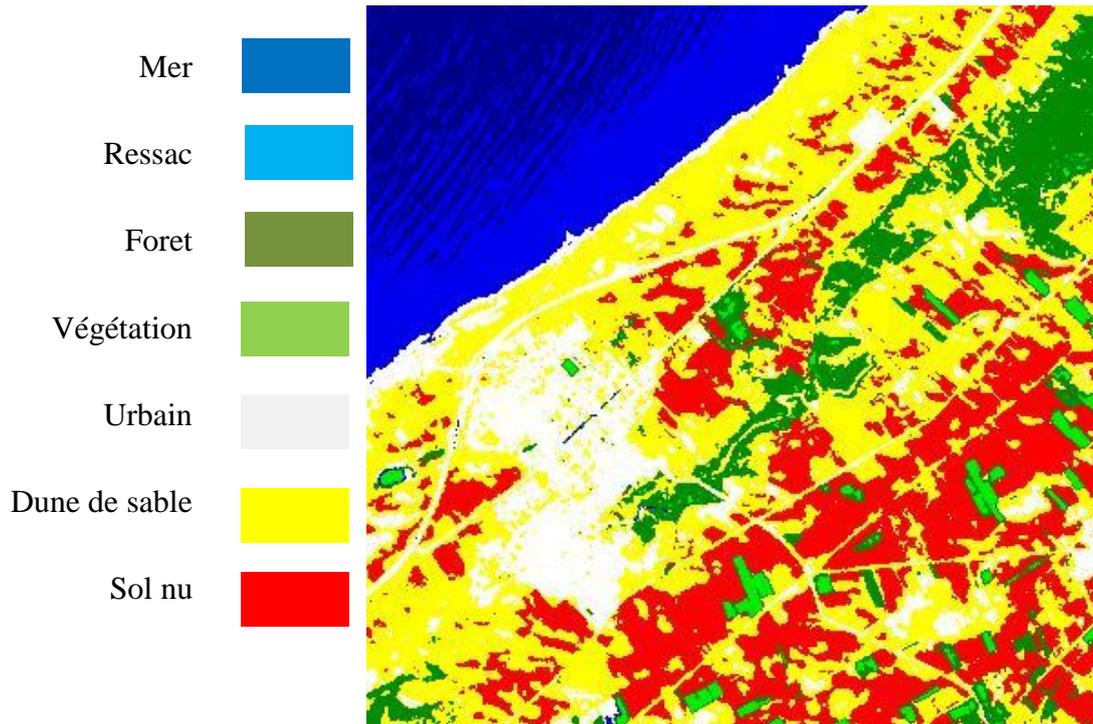


Figure 4.5: Classification MLP/GSA avec la taille de population=50.

Taux : 88.68%	Mer	Ressac	Urbain	Foret	Végétation	Sol nu	Dune de sable
non classés	0	0	0	0	0	0	0
Mer	100	0	0	0	0	0	0
Ressac	0	100	0	0	0	0	0
Urbain	0	0	97.51	0	0	0	22.62
Foret	0	0	0	95.71	19.13	0	0
Végétation	0	0	0	4.02	80.87	0	0
Sol nu	0	0	0	0	0	69.31	0
Dune de sable	0	0	2.49	0.27	0	30.69	77.38
Total	100	100	100	100	100	100	100

Tableau 4.7 : Matrice de confusion relative à la classification MLP/GSA

Chapitre 04 : Implémentation et résultats

L'analyse des statistiques obtenues à partir de la matrice de confusion, dans le tableau 4.7, associée à la classification MLP/GSA, révèle des confusions entre les thèmes végétation et forêt. Néanmoins, la classe dune de sables reste mal classée, avec une grande confusion avec la classe sol nu. Le taux de précision globale est égal à 88.68% avec la taille de population=50.

4.4.4.3 Classification MLP/ PSO GSA

Cette section combine PSO et GSA pour optimiser MLP.

Dans cette étape nous appliquons l'algorithme PSO GSA à l'apprentissage de réseau de neurone pour la classification de l'image de Stidia.

L'algorithme a plusieurs paramètres à fixer à priori. Après plusieurs tests les paramètres de l'algorithme sont choisis comme suite:

C1, C2 (Constantes personnels et sociales)	: 2
W_{\max} (Poids d'inertie maximal)	: 0.9
W_{\min} (Poids d'inertie minimal)	: 0.2
Coefficient gravitationnel initial G_0	: 1
Constant α	: 20
Nombre maximal d'itérations	: 5000
La taille de population	: de 10 à 50

a- Résultats

De la même façon nous avons varié tous la taille de la population et on a fixé le nombre de neurones de la couche cachée. Les résultats sont illustrés dans le tableau 4.8 et le tableau 4.9.

Chapitre 04 : Implémentation et résultats

08 neurones de la couche cachée

10	20	30	40	50
88.92%	89.77%	90.15%	89.92%	92.06%

Tableau 4.8 : Précisions globales obtenues par le classifieur MLP/PSOGSA en variant la taille de population.

08 neurones de la couche cachée

10	20	30	40	50
0.02898	0.02348	0.021452	0.02321	0.01345

Tableau 4.9 : EQM obtenues par le classifieur MLP/PSOGSA en variant la taille de population.

Le tableau 4.8 et 4.9 montre une amélioration dans la valeur de l'erreur quadratique moyenne et précision globale avec l'augmentation du nombre de taille de population.

Nous remarquons que la classification MLP/PSOGSA apporte une nette amélioration à la précision des résultats et l'erreur quadratique moyenne. En effet, les meilleurs taux des précisions globales sont obtenus pour (taille de population=50) avec 92.06% et EQM= 0.01345.

Chapitre 04 : Implémentation et résultats

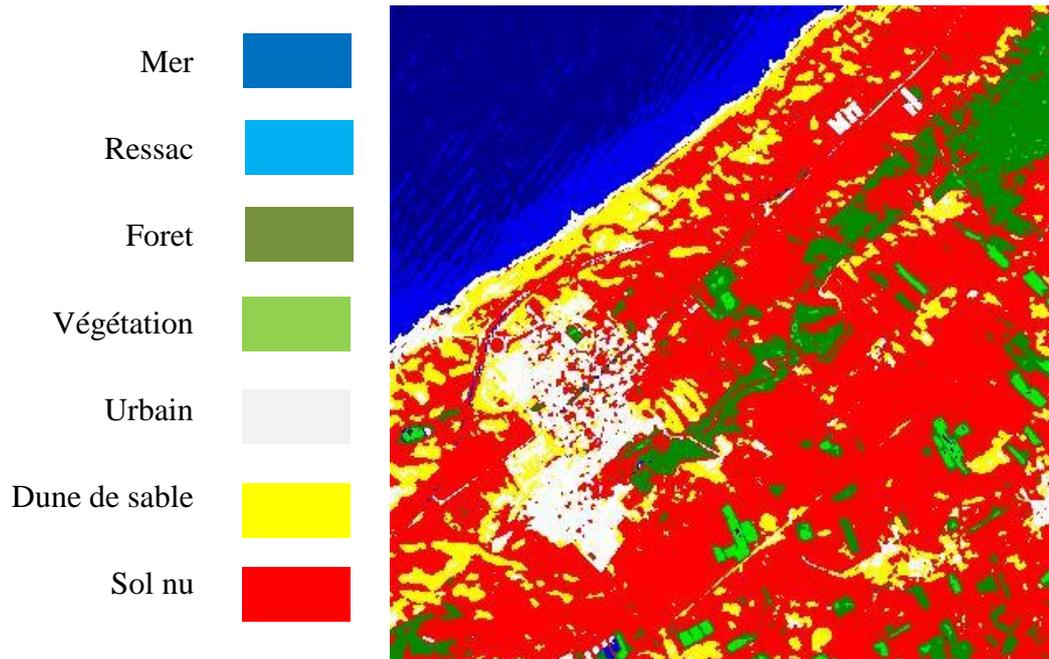


Figure 4.6: Classification MLP/PSOGSA avec la taille de population=50.

Taux : 92.06%	Mer	Resac	Urbain	Foret	Végétation	Sol nu	Dune de sable
non classés	0	0	0	0	0	0	0
Mer	100	0	0	0	2.61	0	0
Resac	0	100	0	0	0	0	0
Urbain	0	0	93.88	0	0	0	18.08
Foret	0	0	0	98.66	14.69	0	0
Végétation	0	0	0	1.07	82.70	0	0
Sol nu	0	0	1.13	0.27	0	100	12.69
Dune de sable	0	0	4.99	0	0	0	69.23
Total	100	100	100	100	100	100	100

Tableau 4.10 : Matrice de confusion relative à la classification MLP/PSOGSA

L'analyse des matrices de confusions issues de la classification MLP/PSOGSA, montrent les bons résultats obtenus. Le tableau 4.10 présente la matrice de confusion relative à la classification de l'ensemble d'apprentissage, où la précision totale de classification a atteint 92.06%.

Chapitre 04 : Implémentation et résultats

D'après la matrice de confusion associée à la classification de l'ensemble de validation, illustrée dans la figure 4.6, les confusions entre les thèmes forêt et végétation ont été réduites de façon considérable, où 82.70% des pixels de la classe végétation sont correctement classés. Même la confusion qui existait au niveau de la classe sol nu, a été minimisée, où le pourcentage des pixels correctement classés est passé à 100%. Les légères confusions restantes constatées entre les classes dune de sable et urbain, peuvent être dues au comportement de ses thèmes dans les bandes spectrales utilisées.

4.4.4.4 Comparaison entre les trois algorithmes

On essaye de varier entre le nombre de neurone de la couche cachée dans une architecture d'un réseau MLP qui comporte une seule couche cachée, voici deux tableaux représentatifs des résultats obtenus après plusieurs essais. Résultats en précision global (tableau 4.11 et figure 4.7) et en erreur quadratique moyenne (tableau 4.12) de trois classifieurs.

	08 neurones	10 neurones	12 neurones	14 neurones	16 neurones
MLP/GSA	88.68%	88.87%	89.02%	88.20%	90.76%
MLP/PSO	91.26%	92.26%	92.42%	93.63%	91.69%
MLP/PSOGSA	92.06%	93.89%	94.47%	91.88%	95.91%

Tableau 4. 11: Précisions globales obtenues par les trois classifieurs en variant le nombre de neurone de la couche cachée

Chapitre 04 : Implémentation et résultats

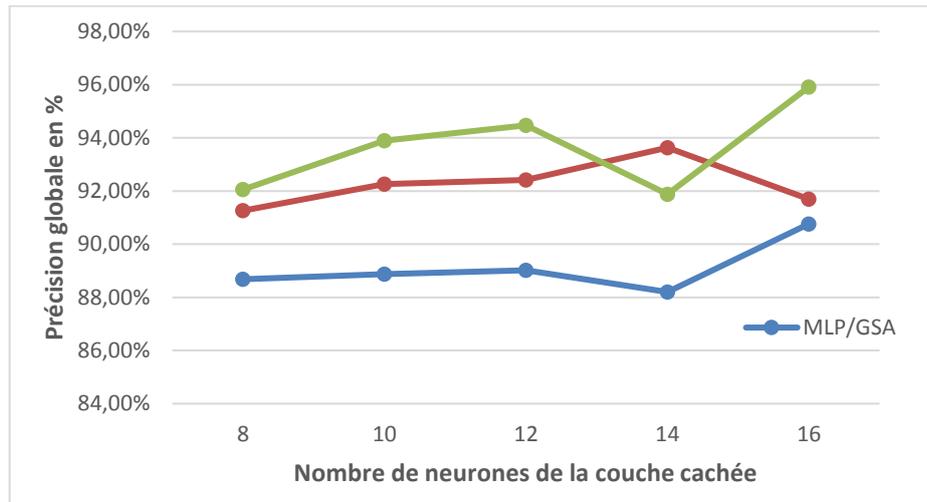


Figure 4.7 : Précisions globales relatives aux différentes expérimentations.

	08 neurones	10 neurones	12 neurones	14 neurones	16 neurones
MLP/GSA	0.04478	0.04157	0.03218	0.04633	0.02191
MLP/PSO	0.01479	0.01336	0.01318	0.01227	0.01452
MLP/PSOGSA	0.01345	0.00978	0.00420	0.01408	0.00175

Tableau 4.12 : EQM obtenues par les trois classifieurs en variant le nombre de neurone de la couche cachée.

Les tableaux 4.11 et 4.12 illustrent les précisions globales et EQM de la classification MLP/GSA, MLP/PSO et MLP/PSOGSA. Ces résultats montrent clairement que la variation du nombre de neurone de la couche cachée influe sur les résultats obtenus. En fixant la taille de population à 50.

Avec le nombre de neurone de la couche cachée est égal à 16, nous obtenons des meilleurs résultats de classification à partir de MLP/GSA et MLP/PSOGSA par contre le classifieur MLP/PSO donne ces meilleurs résultats avec 14 neurones caché.

Chapitre 04 : Implémentation et résultats

Les tableaux 4.11 et 4.12 donne les meilleurs résultats de classification par MLP/PSOGSA (précision globale = 95.91% et EQM=0.00175) parmi tous les algorithmes utilisés. Cette précision globale est supérieure à celle obtenue à partir de MLP/PSO de 2% et celle obtenue à partir de MLP/GSA de 5%.

Les figures 4.8, 4.9 et 4.10 apportent une illustration visuelle aux meilleures classifications obtenues pour chaque classifieur.

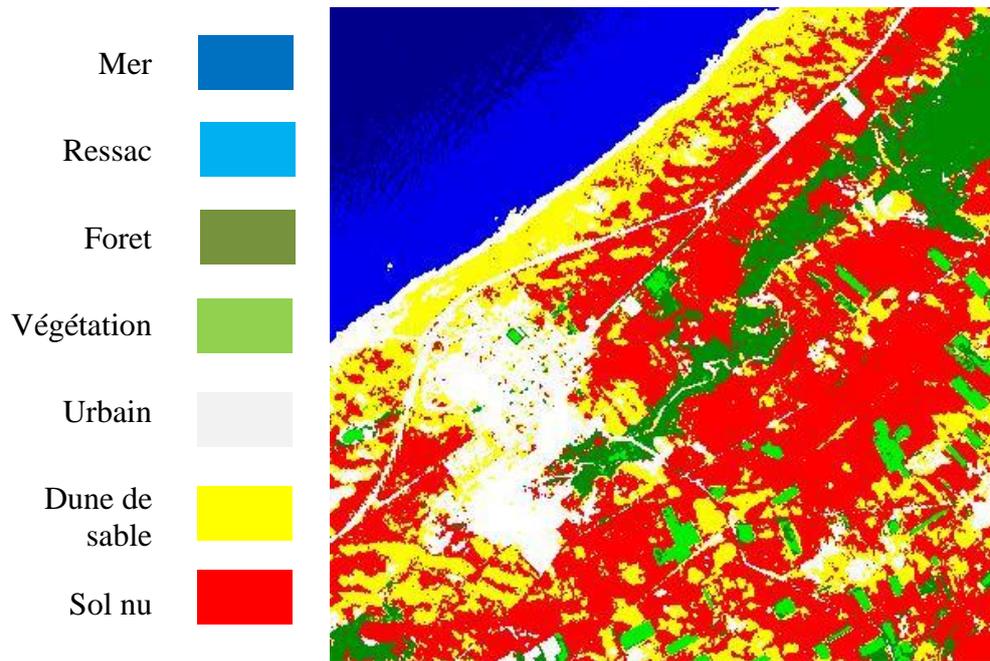


Figure 4.8 : Classification par MLP/PSOGSA

Taux : 95.91%	Mer	Resac	Urbain	Forêt	Végétation	Sol nu	Dune de sable
non classés	0	0	0	0	0	0	0
Mer	100	0	0	0	0	0	0
Resac	0	100	0	0	0	0	0
Urbain	0	0	96.60	0	0	0	12.56
Forêt	0	0	0	91.69	4.35	0	0
Végétation	0	0	0	8.31	95.65	0	0
Sol nu	0	0	0	0	0	100	0
Dune de sable	0	0	3.4	0	0	0	87.44
Total	100	100	100	100	100	100	100

Tableau 4. 13: Matrice de confusion relative à la classification par MLP/PSOGSA

Chapitre 04 : Implémentation et résultats

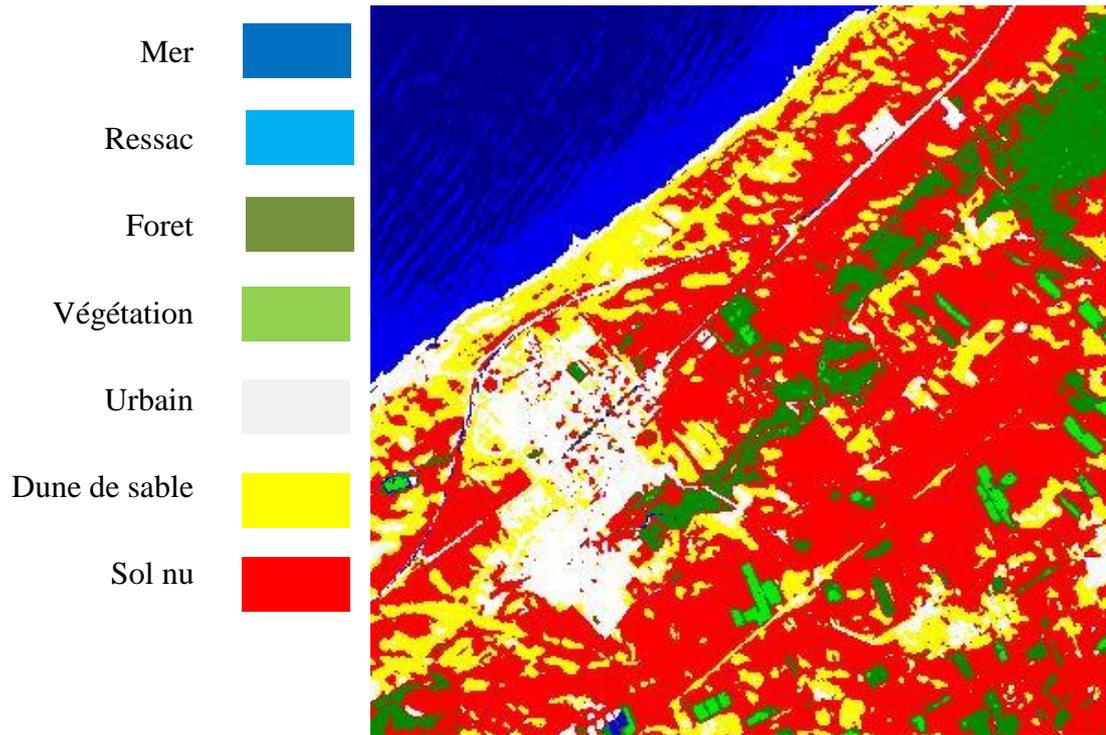


Figure 4.9: Classification par MLP/PSO

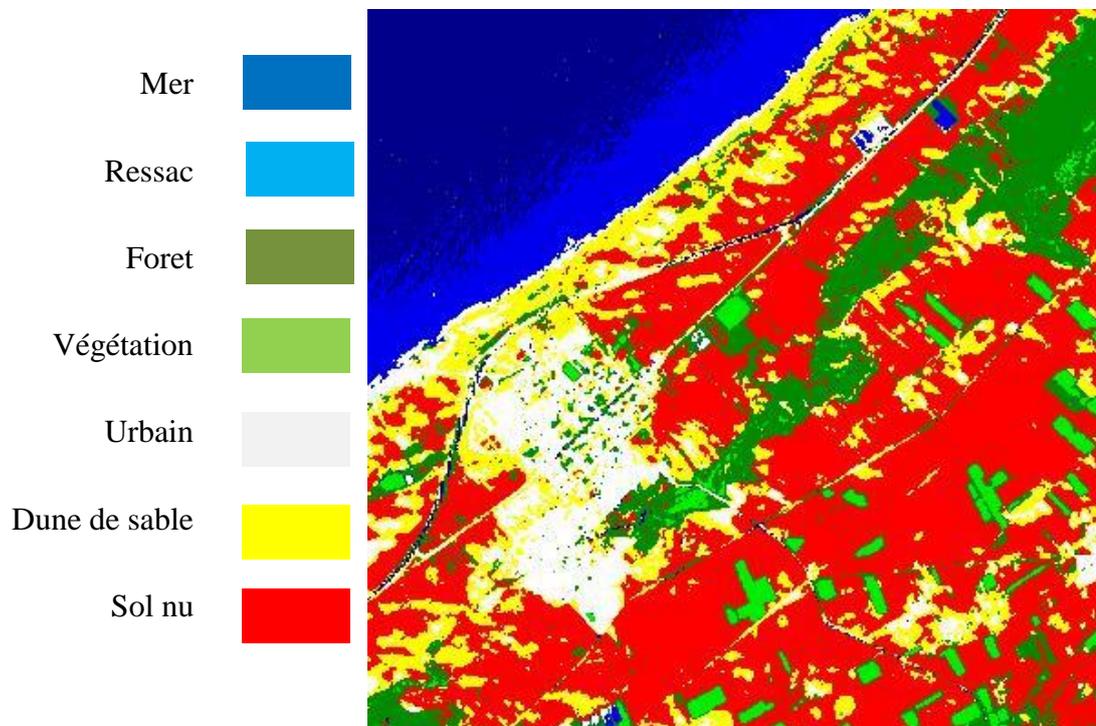


Figure 4.10 : Classification par MLP/GSA

Chapitre 04 : Implémentation et résultats

4.4.4.5 Comparaison avec retro propagation du gradient

Dans cette section, les résultats obtenus par les trois classifieurs utilisés, à savoir, le MLP/PSO, le MLP/GSA et le MLP/PSOGSA sont comparés avec l'algorithme (BP) retro propagation du gradient. Rappelons que ces algorithmes sont utilisées les paramètres suivants :

La taille de population : 50
Nombre maximal d'itérations : 5000
Nombre de neurone de la couche cachée : 16

Le tableau suivant représente les résultats obtenus sur la même image satellitaire de Stidia.

	MLP/ BP	MLP/ GSA	MLP/ PSO	MLP/ PSOGSA
Précision globale	82.99%	90.76%	93.63%	95.91%
EQM	0.42715	0.02191	0.01227	0.00175
Temps(S)	1404.638 s	700.471s	632.984s	635.956 s

Tableau 4.14 : Comparaison des précisions globales, EQM et le temps d'exécutions des classifieurs

Le tableau 4.14, résume les résultats de différents algorithmes appliqués à l'apprentissage du réseau de neurone MLP pour la classification d'image satellitaire.

Les résultats obtenus par l'algorithme PSOGSA, sont extrêmement performants, la précision globale obtenue est supérieure comparées à celles obtenues par les autres algorithmes et la plus petite valeur d'EQM est obtenu par cette algorithme.

Chapitre 04 : Implémentation et résultats

Nous avons remarqué que le temps d'exécution est inférieur dans le cas de la classification par MLP/PSOGSA et MLP/PSO par rapport à autres classifications.

Les résultats obtenus par le classifieur MLP/PSOGSA sont intéressants par rapport au MLP/PSO, MLP/GSA et MLP/rétro propagation (BP) en termes de précision globale, l'erreur quadratique moyenne et le temps d'exécution.

Ainsi pour la détection de changement par comparaison post classification, l'étape de classification sera réalisée en utilisant cette approche.

La figure 4.11 illustre les précisions globales des classifieurs MLP/BP, MLP/GSA, MLP/PSO et MLP/PSOGSA.

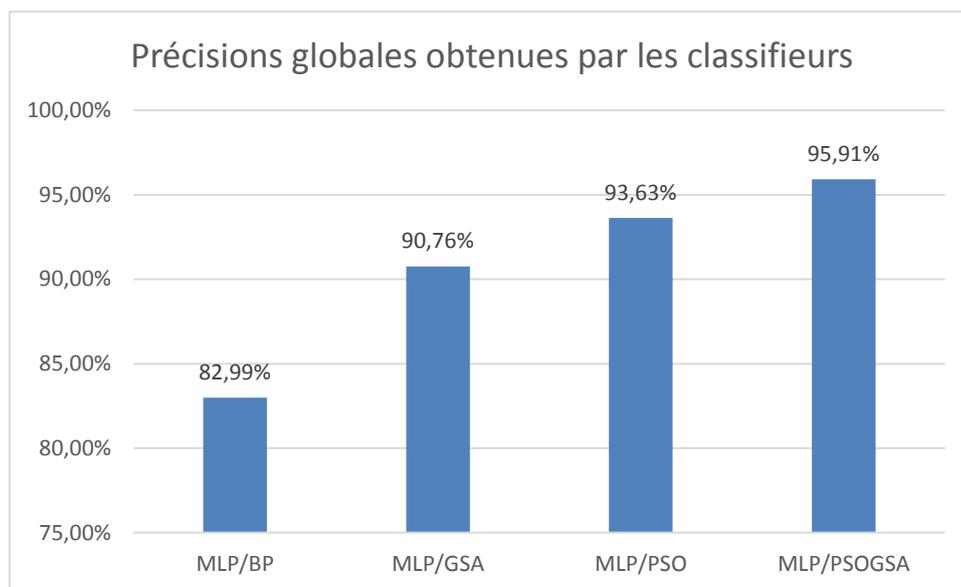


Figure 4.11: Histogramme représentant les précisions globales obtenues par les classifieurs.

La figure 4.12 illustre les EQMs des classifieurs MLP/BP, MLP/GSA, MLP/PSO et MLP/PSOGSA.

Chapitre 04 : Implémentation et résultats

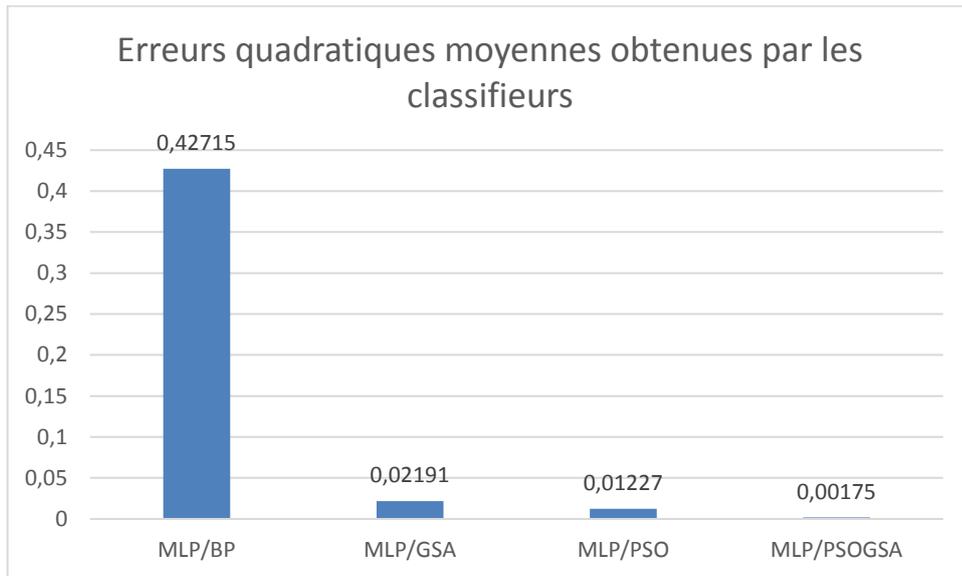


Figure 4.12: Histogramme représentant EQM obtenues par les classifieurs.

4.5 Détection de changements

L'objectif d'utiliser des données optiques multi-temporelles est d'aboutir à des cartes d'occupation du sol plus détaillées et plus riches en informations. Il s'agit donc de considérer les résultats de l'image à haute résolution la plus récente, à savoir l'image Landsat-8 de l'année 2020, avec la prise en compte des différents changements temporels survenus relativement à la classification des images satellitaires.

Chapitre 04 : Implémentation et résultats

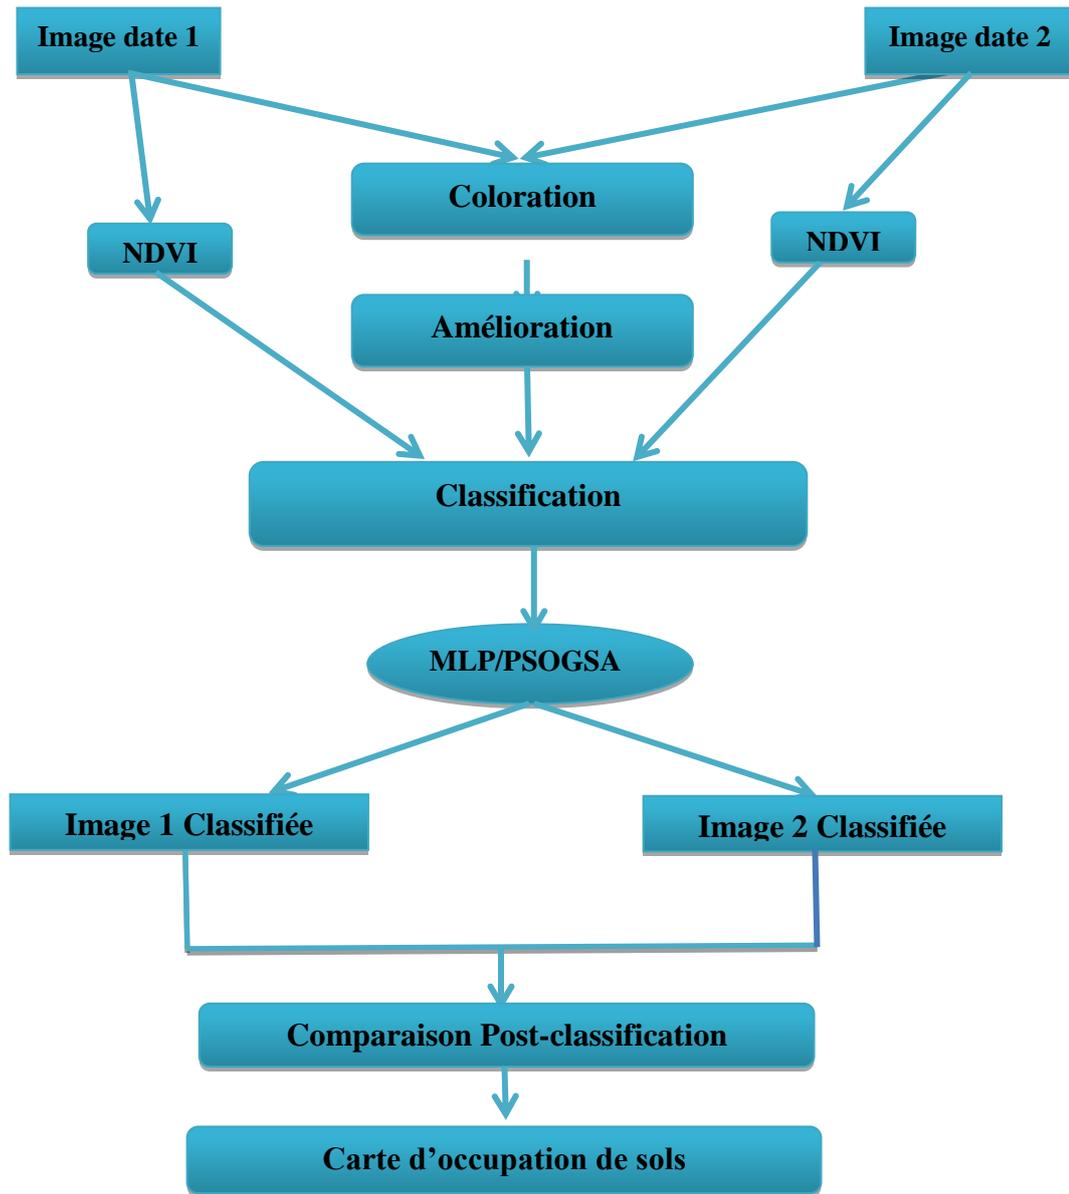


Figure 4.13 : Schéma générale de l'approche proposée

4.5.1 Données utilisées

Suite aux incendies survenus le 25 juillet 2020 dans les communes de Bir El Djir et Hassi Ben Okba (Wilaya d'Oran) située dans la forêt des Lions, couvrant les zones touchées par les feux de forêts, on a analysé deux images satellitaires.

Chapitre 04 : Implémentation et résultats

Les traitements effectués sur ces images satellitaires multi-temporelles de la même zone provenant de capteur Landsat-8, ont permis d'élaborer des cartes d'occupation du sol détaillées à différentes dates de la zone étudiée, et de mesurer la dégradation du tissu Maquis.



Figure 4.14 : Localisation de la zone touchée par les feux de forêts

Le Maquis désigne une formation végétale caractéristique des régions au climat méditerranéen.

On a analysé l'imagerie satellitaire du 29 Juin 2020, et le 31 juillet 2020. Ces dernières sont de taille (400 x 400).

Types de données	Date de prise de vue	Résolution spatiale	Système de projection
Image Landsat 8-OLI	29/06/2020	30 m	WGS 84 UTM
	31/07/2020	30 m	Zone 30 Nord

Tableau 4. 15: Caractéristiques des images Landsat utilisées

Chapitre 04 : Implémentation et résultats



Figure 4. 15: L' image satellitaire d'Oran 29/06/2020



Figure 4.16 : L'image satellitaire d'Oran 31/07/2020

Nous avons téléchargé ces images gratuitement par le site USGS².

² <http://earthexplorer.usgs.gov/>

Chapitre 04 : Implémentation et résultats

Après avoir classifié les deux images à des dates différentes en intégrant l'indice NDVI, nous procédons à l'extraction de la carte de changement en utilisant la comparaison post-classification.

Nous avons opté pour l'indice de végétation de différence normalisée (NDVI) qui est largement utilisé en télédétection pour générer une image illustrant le couvert végétal.

Indice de végétation « NDVI »

Il utilise explicitement la grande différence entre les réflectances du rouge et du proche infrarouge. Cependant, cet indice c'est efficacement utilisable que pendant les périodes végétatives, lorsque l'activité chlorophyllienne est importante.

Bande 4 (rouge, 0,64 μm à 0,67 μm) pour Landsat-8 – Portion de la lumière utilisée pour la détection de l'activité chlorophyllienne des végétaux; apporte de nettes distinctions entre les zones de végétation et celles qui en sont dépourvues.

Bande 6 (infrarouge à ondes courtes 1,57 μm à 1,65 μm) des images Landsat-8 – Sensible à l'humidité des sols et de la végétation, détecte la chlorophylle; bande très contrastée, peu sensible aux effets atmosphériques;

Utilisation d'outil télédétection nous a permis de faire une classification d'image satellitaire. Cette classification fait ressortir six classes on fonction de type occupation (Mer, Maquis, Terres agricoles, Jachères, Urbain et Sol nu).

Les indices NDVI des deux images sont illustrées dans les figures suivantes.

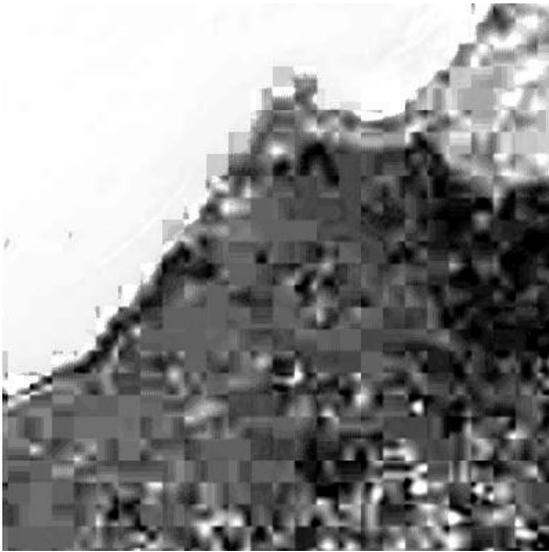


Figure 4. 17: Indice de végétation NDVI appliqué sur l'image 29/06/2020.

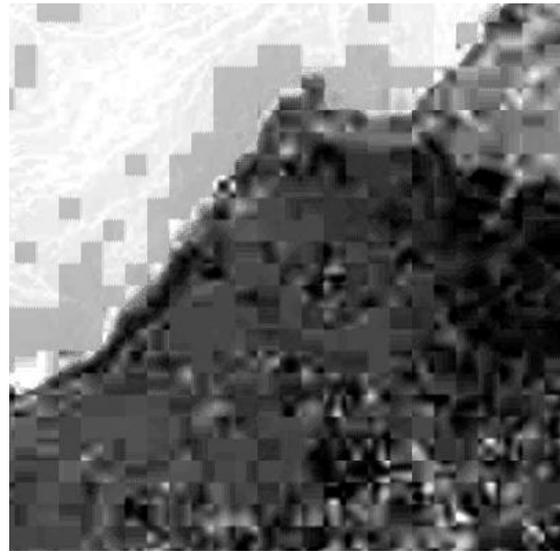


Figure 4.18 : Indice de végétation NDVI appliqué sur l'image 31/07/2020.

4.5.2 Résultats de la classification

A l'issue des résultats obtenus par les deux images et afin de juger de la qualité des changements obtenus, nous avons effectué une classification supervisée par le classifieur MLP/ PSO GSA. Dans un premier temps, nous combinons les données spectrales avec les indices NDVI de chaque image, sachant que le nombre de neurone de la couche d'entrée est égale à 04, par la suite, les résultats issus des classifications permettent de quantifier le couvert forestier et de mettre en évidence son emprise à différentes dates.

La précision globale et le coefficient Kappa sont utilisés pour évaluer chaque classification. Les résultats sont reportés dans le tableau 4.16.

Chapitre 04 : Implémentation et résultats

	Précision globale (%)	Coefficient de Kappa
Image de 29/06/2020	97,59	0,9462
Image de 31/07/2020	94,94	0,9117

Tableau 4. 16: Pourcentages des classifications MLP/PSOGSA pour les deux images.

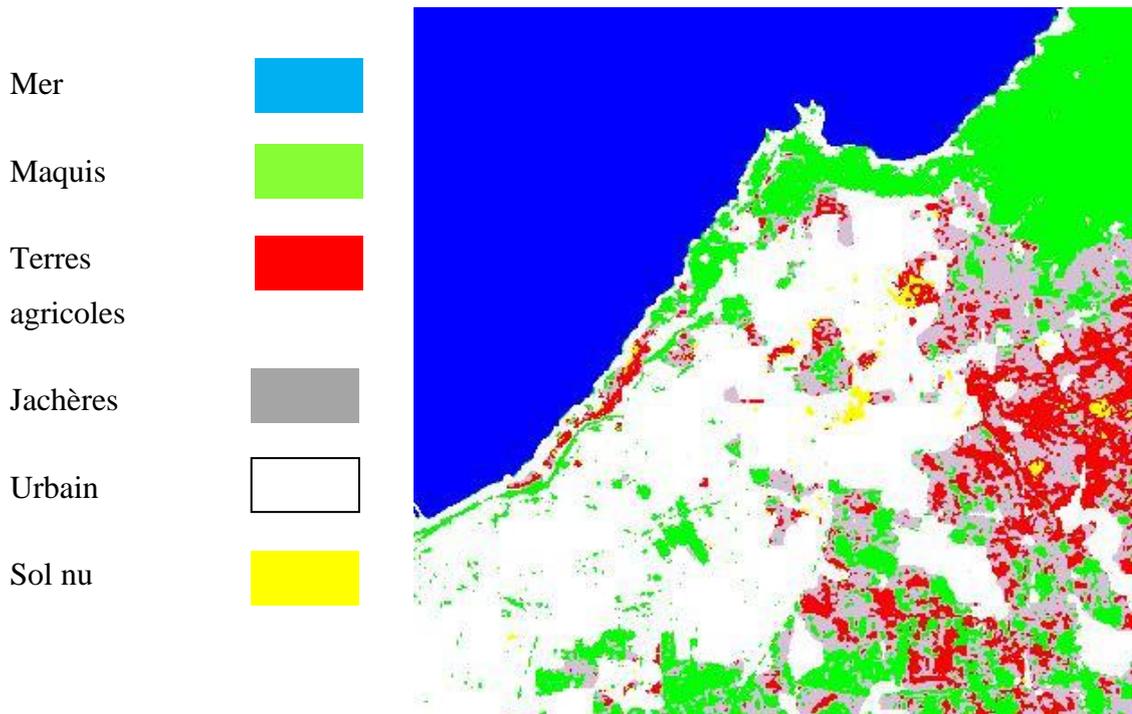


Figure 4.19 : Classification d'image LANDSAT-8 de 29/06/2020.

La précision globale représente le rapport du nombre de pixels bien classés sur le nombre total de pixels. Elle est de 97,59 %, et 94,94 % respectivement pour les deux images de changements 29/06/2020 et 31/07/2020. Le coefficient Kappa qui correspond également à un autre indice de précision variant entre 0 et 1, indique avec des valeurs comprises entre 0,91 et 0,94 une bonne qualité de la classification (Tableau 4.16).

Chapitre 04 : Implémentation et résultats

Taux : 97.59%	Mer	Maquis	Terres agricoles	Jachères	Urbain	Sol nu
non classés	0	0	0	0	0	0
Mer	100	0	0	0	0	0
Maquis	0	97.69	0.45	2.45	1.77	0
Terres agricoles	0	0	93.33	1.25	0	0
Jachères	0	2.31	6.22	96.30	0	0
Urbain	0	0	0	0	98.23	0
Sol nu	0	0	0	0	0	100
Total	100	100	100	0	100	100

Tableau 4.17 : Matrice de confusion relative à la classification d'image de 26/30/2020.

Comme l'illustre le tableau 4.17 la classification a donnée des confusions légères entre les classes thématiques. Notamment entre Maquis et Jachères, où 2.31% des pixels de validation de la classe Maquis sont affectés à Jachères, et 1.25% des pixels de cette dernière, sont affectés à la classe Terres agricoles. 6.22% des pixels de la classe Terres agricoles sont affectés aux classes Jachères et 0.45% aux Maquis.

Chapitre 04 : Implémentation et résultats

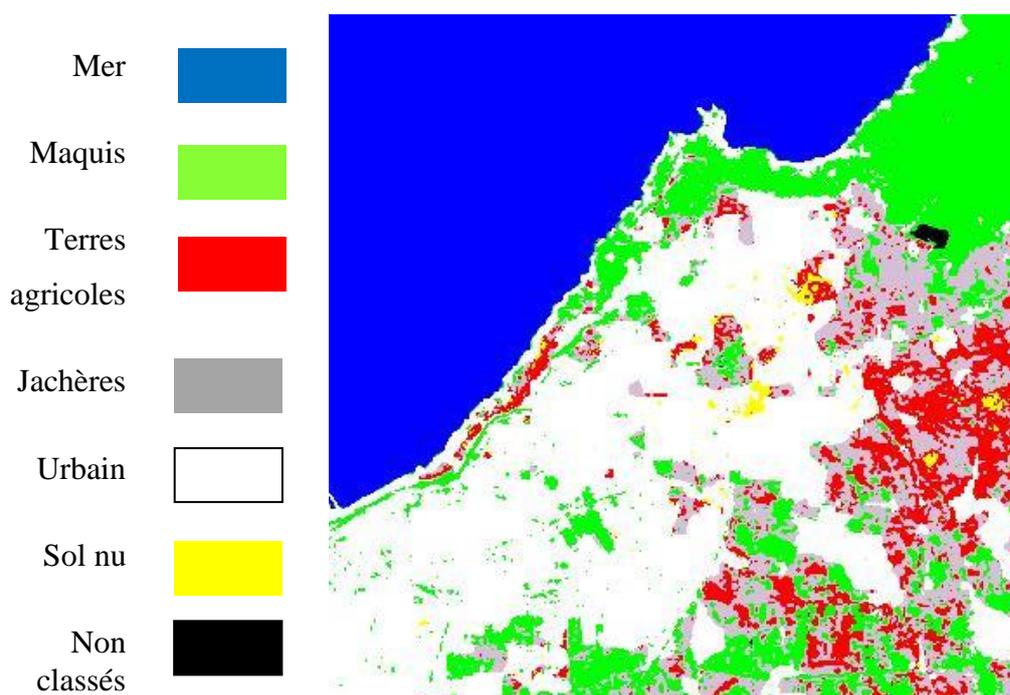


Figure 4.20 : Classification d'image LANDSAT 8 de 31/07/2020

Taux : 94.94%	Mer	Maquis	Terres agricoles	Jachères	Urbain	Sol nu
non classés	0	13.61	0	0	0	0
Mer	100	0	0	0	0	0
Maquis	0	81.25	2.21	2.43	2.44	0
Terres agricoles	0	0	94.05	0.77	0	0
Jachères	0	5.14	3.74	96.80	0	0
Urbain	0	0	0	0	97.56	0
Sol nu	0	0	0	0	0	100
Total	100	100	100	0	100	100

Tableau 4.18 : Matrice de confusion relative à la classification d'image de 31/07/2020.

Chapitre 04 : Implémentation et résultats

L'analyse des statistiques obtenues à partir de la matrice de confusion, dans le tableau 4.18, associée à la classification d'image de 31/072020, la précision globale a diminué de 2.65% par rapport à la précision globale de la première classification. Un nouveau classement des pixels de la classe Maquis sont non classés.

Le croisement des deux cartes Figure 4.21, montre clairement le changement soit régressive du patrimoine Maquis, suite aux incendies survenus durant cette période.

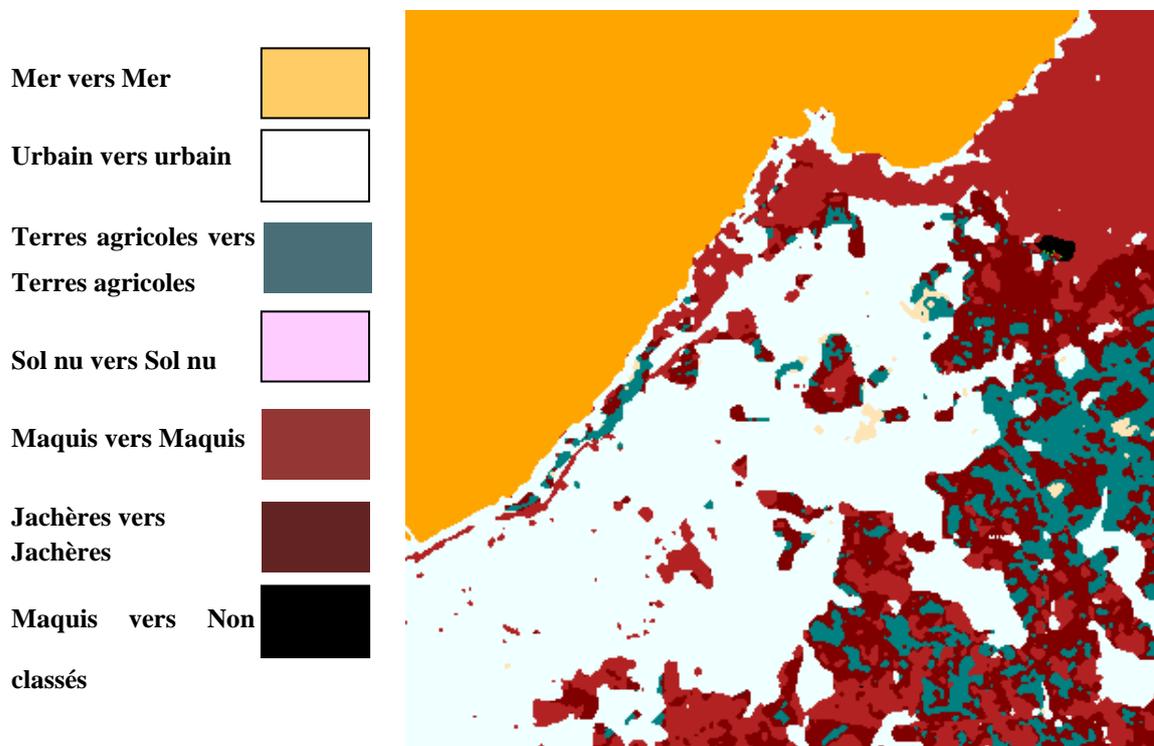


Figure 4.21 : Carte des changements.

Cette analyse a permis de localiser les impacts de feu, couvrant une superficie totale parcourue par le feu située dans la forêt des Lions.

Chapitre 04 : Implémentation et résultats

Changement entre 29-06-2020 et 31-07-2020	Superficie (ha)	Superficie (%)
Mer vers Mer	4495,59	31.21%
Urbain vers Urbain	4786,29	33.23%
Terres agricoles vers Terres agricoles	978,48	6.79%
Jachères vers Jachères	1784,70	12.39%
Sol nu vers Sol nu	79,56	0,55%
Maquis vers Maquis	2257,15	15.67%
Maquis vers Non classées	19,87	0,138%

Tableau 4.19 : Superficie de changement entre 29-06-2020 et 31-07-2020.

L'analyse de la carte Figure 4.21 et le Tableau 4.19, issue par le croisement des cartes d'occupation de sol de 29/06/2020 et 31/07/2020, montre une dynamique au niveau de classe thématique Maquis. On constate que plus de 99.86% de la zone d'étude n'ont pas subi de changements. Tandit que parmi les unités d'occupation des sols qui ont subi des modifications, c'est les surfaces Maquis qui ont connu une régression de 0,138 % soit 19.87 ha justifiée par les incendies survenus le 25 juillet 2020.

4.6 Conclusion

Dans ce chapitre, nous avons réalisé trois classifications neuronales MLP combinés par trois méta heuristiques à savoir PSO, GSA et PSO GSA sur deux images satellitaire de la région de stidia et Oran.

Le résultat de la classification a été utilisé dans la détection de changement par la technique post classification.

Chapitre 04 : Implémentation et résultats

Ces méta heuristiques sont parmi les méthodes les plus connues dans ce cadre puisque leurs résultats ont été très intéressants dans plusieurs domaines d'application et notamment dans la télédétection en prenant compte de leur hybridation neuronale.

Les résultats de classification ont été performants en termes de précisions globales et de la minimisation d'erreur quadratique moyenne, et en temps d'exécutions en Comparant aux différentes méthodes (PSO, GSA et BP) appliquées à l'image satellitaire. On peut conclure que la méthode PSOGSA est très performante, et très attractive pour la classification des images.

La détection des changements dépend de la qualité de la classification qui nous a permis de localiser avec précisions les transformations de l'espace forestier d'Oran (Hassi Ben Okba).

Conclusion Générale

Conclusion générale

Notre travail a pour objectif d'appliquer les méta-heuristiques au traitement d'images, le traitement d'images est un vaste domaine, nous avons limité nos recherches pour résoudre le problème de classification des images satellitaires issues du mécanisme de la télédétection (image satellitaire) par le réseau de neurone de type perceptron multicouche optimisé par les algorithmes métaheuristiques tels que PSO (l'optimisation par essaim de particules), GSA (l'algorithme de recherche gravitationnelle) et PSO-GSA (l'hybridation de l'optimisation par essaim de particules et l'algorithme de recherche gravitationnelle) qui seront par la suite utilisées dans le processus de détection de changements (post-classification).

Dans le but d'évaluer la précision des classifications et la valeur de l'erreur quadratique moyenne, nous avons appliqué nos approches sur une image Sentinel de la région de Stidia (Mostaghanem) en Algérie. Les résultats obtenus démontrent l'efficacité de PSO-GSA et aussi le PSO à l'apprentissage de MLP avec un peu de supériorité par rapport au GSA, les expérimentations qui nous avons effectuées ont bien montré que l'hybridation permet d'améliorer le résultat de classification, d'un autre côté on a constaté que les trois approches (PSO, GSA et PSO-GSA) sont très influencées par les différents paramètres tel que la taille de la population et le nombre de neurone de la couche cachée.

Le classifieur MLP/PSO-GSA donnent des résultats intéressants par rapport au, PSO, GSA et rétro propagation (BP) en termes de précision globale et l'erreur quadratique moyenne.

Conclusion générale

En appliquant l'approche MLP/PSOGSA sur des données Landsat-8 multi-temporelles, pour la comparaison post-classification, nous constatons que la qualité de la classification affecte sérieusement les résultats de la détection de changement et peut sous-estimer quelques zones de changement de couverture terrestre.

Les résultats obtenus ont bien montré des changements qu'a connus ce couvert végétal où, de 29/06/2020 à 31/07/2020, une évolution régressive de 15.67% a été constatée sur la surface de Maquis.

En perspective de recherche, il serait intéressant d'optimiser d'autre classifieur tel que réseau de neurones de convolution, SVM (Séparateurs à Vastes Marges) par l'algorithme métaheuristique PSOGSA sur d'autres types d'images, à différentes résolutions et issues d'autres types de capteurs.

Références Bibliographiques

Contributions

Publications:

Meriem Abidi, Hadria Fizazi, Nourredine Boudali, **Clustering of Remote Sensing Data Based on Spherical Evolution Algorithm**, International Review of Aerospace Engineering (I.RE.AS.E), Vol. 14, N. 2, April 2021

Nourredine Boudali, Hadria Fizazi, Meriem Abidi, **Texture Features Extraction and Backtracking Search Optimization Algorithm for Satellite Image Clustering**, *International Review of Aerospace Engineering (I.RE.AS.E)*, Vol. 12, N. 5 ISSN1973-7459 October 2019

Conférences:

Hadria Fizazi, Meriem Abidi, « **Intégration des paramètres pertinents de la texture dans le processus classificatoire des images satellitaires** », Conférences Internationale sur le traitement de l'information multimédia, CITIM'2012, Avril 2012

Résumé

L'utilisation de données de télédétection est une méthode très importante pour indiquer les changements d'occupation de sols. La télédétection peut fournir une meilleure image qui permet de localiser des zones géographiquement modifiées.

L'objectif de notre travail était d'appliquer une approche de détection de changements basée sur l'utilisation de la méthode post-classification d'images satellitaires multi-temporelles Landsat -8 afin d'isoler les pixels changés. La qualité de l'image classifiée affecte la précision de la détection de changements. Ainsi, nous proposons une classification supervisée d'une image satellitaire en utilisant un réseau de neurone MLP (perceptron multi couche) optimisé par trois algorithmes PSO (l'optimisation par essaim de particules), GSA (l'algorithme de recherche gravitationnelle) et PSOGSA (l'hybridation de l'optimisation par essaim de particules et l'algorithme de recherche gravitationnelle) qui seront ensuite utilisés le résultat de classification dans le processus de détection de changements qui permis d'analyser les changements et d'identifier les zones de dégradation.

Les résultats expérimentaux prouvent le succès de ces techniques à la classification des images satellitaires, et montrent l'état des couverts forestiers de notre zone d'étude qui a perdu de 19.87 ha justifiée par les incendies.

Mots clés : Télédétection, images satellitaires, détection des changements, métaheuristique.

Abstract

The use of remote sensing data is a very important method to indicate changes in land use. Remote sensing can provide a better image that makes it possible to locate geographically modified areas.

The objective of our work was to apply a change detection approach based on the use of the post-classification method of multi-temporal Landsat -8 satellite images to isolate the changed pixels. The quality of the image classifier affects the accuracy of change detection. Thus, we propose a supervised classification of a satellite image using an MLP (multilayer perceptron) neuron network optimized by three algorithms PSO (particle swarm optimization), GSA (the gravitational search algorithm) and PSOGSA (the hybridization of particle swarm optimization and the gravitational search algorithm) which will then be used the result of classification in the process of change detection to analyze the changes and identify areas of degradation.

The experimental results prove the success of these techniques in the classification of satellite images, and show the state of the forest cover in our study area, which lost 19.87 ha due to fires.

Keywords: Remote sensing, satellite images, change detection, metaheuristic.

المخلص

يعد استخدام بيانات الاستشعار عن بعد طريقة مهمة للغاية لاستخراج التغيرات في الغطاء الأرضي. يمكن أن يوفر الاستشعار عن بعد أفضل صورة تساعد في تحديد المناطق المتغيرة جغرافياً.

كان الهدف من الأطروحة هو تطبيق طريقة لاكتشاف التغيير بناءً على استخدام أسلوب ما بعد التصنيف لصور القمر الصناعي لاندسات -8 في زمنين مختلفين لعزل وحدات البكسل المتغيرة. تؤثر جودة مصنف الصور على دقة اكتشاف التغيير وبالتالي، نقترح تصنيفاً مع الإشراف باستخدام شبكة عصبية MLP محسنة بثلاث خوارزميات: PSO (تحسين سرب الجسيمات) ، GSA (خوارزمية البحث بالجاذبية) و PSOGSA (اندماج تهجين سرب الجسيمات وخوارزمية البحث بالجاذبية) والتي سيتم استخدامها بعد ذلك نتيجة التصنيف في عملية الكشف عن التغيير والتي تسمح بتحليل التغيرات وتحديد مناطق التدهور. وأثبتت النتائج التجريبية نجاح هذه التقنيات في تصنيف صور الأقمار الصناعية ، وأظهرت حالة الغطاء الغابي في منطقة دراستنا والتي فقدت 19.87 هكتار بسبب الحرائق.

الكلمات المفتاحية : صور الأقمار الصناعية، التصنيف، التحسين، البيانات النسيجية، خوارزمية البحث العكسي.

Références Bibliographiques

(Aadil et al. 2016): Aadil Farhan, Khalid Bashir Bajwa, Salabat Khan, Nadeem Majeed Chaudary, and Adeel Akram. 2016. "CACONET: Ant Colony Optimization (ACO) Based Clustering Algorithm for VANET." *PloS One* 11 (5). Public Library of Science San Francisco, CA USA.

(Aarts et al 2018): Aarts Emile HL, Jan HM Korst, and Peter JM Van Laarhoven. 2018. " Simulated annealing." *Local search in combinatorial optimization*. Princeton University Press, 91-120.

(Albetis et al 2018): Albetis de la Cruz, Johanna Leslie. 2018. "Potentiel des images multispectrales acquises par drone dans la détection des zones infectées par la flavescence dorée de la vigne." Université Toulouse III-Paul Sabatier.

(Aljarah et al 2019): Aljarah Ibrahim, Hossam Faris, Seyedali Mirjalili, Nailah Al-Madi, Alaa Sheta, and Majdi Mafarja. 2019. "Evolving Neural Networks Using Bird Swarm Algorithm for Data Classification and Regression Applications." *Cluster Computing* 22 (4). Springer: 1317–45.

(Arezki et al 2020): Arezki, Dounia ; Fizazi, Hadria ; Belda, Santiago search by orcid ; De Grave, Charlotte ; Pipia, Luca ; Verrelst, Jochem. 2020. "A Machine Learning Software Framework for Extraction of Phenology Indicators from Multi-Temporal Sentinel-2 Images." In *EGU General Assembly Conference Abstracts*, 21952.

(Ansari et al 2020): Ansari Rizwan Ahmed, Krishna Mohan Buddhiraju, and Rakesh Malhotra. 2020. "Urban Change Detection Analysis Utilizing Multiresolution Texture Features from Polarimetric SAR Images." *Remote Sensing Applications: Society and Environment* 20. Elsevier.

(Aslami and Ardavan. 2018): Aslami Farnoosh, and Ardavan Ghorbani. 2018. "Object-Based Land-Use/Land-Cover Change Detection Using Landsat Imagery: A Case Study of Ardabil, Namin, and Nir Counties in Northwest Iran." *Environmental Monitoring and Assessment* 190 (7). Springer: 1–14.

Références Bibliographiques

(Asokan and J Anitha. 2019): Asokan Anju, and J Anitha. 2019. "Change Detection Techniques for Remote Sensing Applications: A Survey." *Earth Science Informatics* 12 (2). Springer: 143–160.

(Badaoui and Namous 2010.): Ali Badaoui, and Namous Nafa. 2010. "Correction radiométrique des images satellitaires application aux scènes hrv de spot." Thèse de doctorat, Université Mouloud Mammeri. Algérie

(Bahlali 2017): Bahlali Mohamed. 2017. "Recuit Simulé Sur Un Espace Fini Avec Relaxation Des Contraintes et Estimation Séquentielle de La Fonction Coût: Application à Un Problème de Découpe." Université Paris-Dauphine, France.

(Bayouhd 2013.): Bayouhd Meriam. 2013. "Apprentissage de Connaissances Structurelles à Partir d'images Satellitaires et de Données Exogènes Pour La Cartographie Dynamique de l'environnement Amazonien." Thèse de doctorat. Université des Antilles et de la Guyane, France

(Benbouzid et al 2006): Benbouzid Sitayeb Fatima, Christophe Varnier, and Nouredine Zerhouni. 2006. "Résolution du problème de l'ordonnancement conjoint production/maintenance par Colonies de Fourmis." In *6ème Conférence Francophone de MOdélisation et SIMulation, MOSIM'06. Modélisation, Optimisation et Simulation Des Systèmes: Défis et Opportunités.*, 10.

(Benhabib and Fizazi 2012): Benhabib Wafaa, and Hadria, Fizazi. 2012. "Approche tribale des SVMs pour la classification des images satellitaires." *Nature & Technology* (6) ,9.

(Benmammar and Amraoui. 2020): Benmammar Badr, and Asma Amraoui. 2020. "Application de l'intelligence Artificielle Dans Les Réseaux de Radio Cognitive." *Gestion et Contrôle Intelligents Des Réseaux: Sécurité Intelligente, Optimisation Multicritères, Cloud Computing, Internet of Vehicles, Radio Intelligente*, 233.

Références Bibliographiques

(Bensaid A. 2021): Bensaid A. 2021. “Apport des images ETM+ et du sig dans la détection des changements dynamiques de l’espace steppique de naâma, Algérie.” *Revue Marocaine Des Sciences Agronomiques et Vétérinaires* 9 (4).

(Berghida, and Mechtri. 2017): Berghida Imène, and Ammar Mechtri. 2017. “Cartographie des efflorescences algales dans le barrage d’el agreem (W. de Jijel) à partir d’images satellitaires.” université de Jijel. Algérie

(Bhandari et al 2015): Bhandari Ashish Kumar, Anil Kumar, and Girish Kumar Singh. 2015. “Modified Artificial Bee Colony Based Computationally Efficient Multilevel Thresholding for Satellite Image Segmentation Using Kapur’s, Otsu and Tsallis Functions.” *Expert Systems with Applications* 42 (3). Elsevier: 1573–1601.

(Bhattacharjee and Pant 2019): Bhattacharjee Kamanasish, and Millie Pant. 2019. “Hybrid Particle Swarm Optimization-Genetic Algorithm Trained Multi-Layer Perceptron for Classification of Human Glioma from Molecular Brain Neoplasia Data.” *Cognitive Systems Research* 58. Elsevier: 173–194.

(Bouaita 2020): Bouaita Bilal. 2020. “Extraction de connaissances à partir de données multi-spectrales: cas des images msg.” Thèse de doctorat , Université Ferhat ABBAS - Sétif 1 , Algérie

(Boudali et al 2019.): Boudali Nourredine, Hadria Fizazi, Meriem Abidi,. 2019. “Texture Features Extraction and Backtracking Search Optimization Algorithm for Satellite Image Clustering” *Praise Worthy, and S Prize* 12 (5): 222–230.

(Boudali 2020): Boudali, Nourredine. 2020. “La Contribution de La Texture Sur La Classification Des Images Satellitaires Par Les Algorithmes Évolutionnistes.” Thèse de doctorat. Université Mohamed Boudiaf Oran, Algérie.

Références Bibliographiques

(Boulila 2012): Boulila Wadii. 2012. “Extraction de Connaissances Spatio-Temporelles Incertaines Pour La Prédiction de Changements En Imagerie Satellitale.” Thèse de doctorat. Télécom Bretagne, Université de Rennes 1. France

(Campbell and Wynne 2011): Campbell James B, and Randolph H Wynne. 2011. *Introduction to Remote Sensing*. Guilford Press.

(Canty 2014): Canty Morton J. 2014. *Image Analysis, Classification and Change Detection in Remote Sensing: With Algorithms for ENVI/IDL and Python*. Crc Press.

(Carvalho and Ludermir 2006): Carvalho Marcio, and Teresa B Ludermir. 2006. “Particle Swarm Optimization of Feed-Forward Neural Networks with Weight Decay.” In *2006 Sixth International Conference on Hybrid Intelligent Systems (HIS'06)*, 5. IEEE.

(Chen Chao et al 2019): Chen Chao, Jiaoqi Fu, Shuai Zhang, and Xin Zhao. 2019. “Coastline Information Extraction Based on the Tasseled Cap Transformation of Landsat-8 OLI Images.” *Estuarine, Coastal and Shelf Science* 217. Elsevier: 281–291.

(Chen al 2017): Chen Tao, John C Trinder, and Ruiqing Niu. 2017. “Object-Oriented Landslide Mapping Using ZY-3 Satellite Imagery, Random Forest and Mathematical Morphology, for the Three-Gorges Reservoir, China.” *Remote Sensing* 9 (4). 333.

(Corgne 2014): Corgne Samuel. 2014. “Étude Des Changements d’occupation et d’usage Des Sols En Contexte Agricole Par Télédétection et Fusion d’informations.” Thèse de doctorat, Université Rennes 2, France.

(Daoudi 2016): Daoudi Dabladji Rima. 2016. “Classification Du Cancer Du Sein Par Des Approches Basées Sur Les Systèmes Immunitaires Artificiels.” Thèse de doctorat, Université Paris-Saclay; France.

(Dasgupta 1993): Dasgupta Dipankar. 1993. “An Overview of Artificial Immune Systems and Their Applications.” *Artificial Immune Systems and Their Applications*. Springer, 3–21.

Références Bibliographiques

(De Estíbaliz et al 2019): De Estíbaliz Martínez, Izquierdo, María Molina Sánchez, and María Iñigo del Carmen Morillo Balsera. 2019. “Efficient Dimensionality Reduction Using Principal Component Analysis for Image Change Detection.” *IEEE Latin America Transactions* 17 (04). IEEE: 540–547.

(Delloul and Rahal 2015): Delloul Ali, Rahal Radouane. 2015. “Application d’un Système Immunitaire Artificiel dans la reconnaissance des surfaces.” Thèse de doctorat, Université de Guelma, Algérie.

(Deroussi. 2016): Deroussi Laurent. 2016. *Métaheuristiques Pour La Logistique*. Vol. 2. ISTE Group.

(Dissanayake 2020): Dissanayake DMSLB. 2020. “Land Use Change and Its Impacts on Land Surface Temperature in Galle City, Sri Lanka.” *Climate* 8 (5), 65.

(Dorais 2011): Dorais Alexis. 2011. “Détection de Points Chauds de Déforestation à Bornéo de 2000 à 2009 à Partir d’images MODIS.” Thèse de doctorat, Université de Montréal, Canada.

(Dorigo and Stützle. 2019): Dorigo Marco, and Thomas Stützle. 2019. “Ant Colony Optimization: Overview and Recent Advances.” In *Handbook of Metaheuristics*, 311–351. Springer.

(Dréo 2003): Dréo Johann. 2003. “Adaptation de la métaheuristique des colonies de fourmis pour l’optimisation difficile en variables continues. Application En Génie Biologique et Médical.” Thèse de doctorat, Université Paris XII Val de Marne, France.

(Drif and Bensaïfia 2018): Drif Asma, and Nesrine Bensaïfia. 2018. “Méthode hybride basée sur les algorithmes à évolution différentielle.” Mémoire de master, Université de Djilali Bounaama Khemis Miliana. Algérie

(El Dor. 2012): El Dor Abbas. 2012. “Perfectionnement des algorithmes d’optimisation par essaim particulaire: applications en segmentation d’images et en électronique.” Thèse de doctorat, Université Paris-Est, France.

Références Bibliographiques

(El Moubarek 2008): El Moubarek B Allal. 2008. "Optimisation par la méthode des essaims particulaires d'une fonction trigonométrique." mémoire magister, Ecole Normale Supérieurs d'Enseignement Technique-ORAN, Algérie.

(El Moussaoui 2020): El Moussaoui El houcin. 2020. "Cartographie de l'arganeraie par télédétection optique et radar à haute résolution spatio-temporelle. Etude de cas : commune rural Smimou.", Mémoire de master, Université Cadi ayyad Marrakech, Maroc.

(Femmam 2016): Femmam Maroua. 2016. "Les cartes heuristiques comme outil pédagogique favorisant l'apprentissage du lexique cas de la 5ème année primaire ecole:«bakhouche mohamed ben laarouci»." université Mohamed khider , Biskra, Algérie.

(Feo and Resende 1995): Feo Thomas A, and Mauricio G C Resende. 1995. "Greedy Randomized Adaptive Search Procedures." *Journal of Global Optimization* 6 (2). Springer: 109–133.

(Fingas and Brown 2014): Fingas Merv, and Carl Brown. 2014 "Review of oil spill remote sensing." *Marine pollution bulletin* 83. (1): 9-23.

(Gandhi et al 2015): Gandhi G Meera, S Parthiban, Nagaraj Thummalu, and A Christy. 2015. "Ndvi: Vegetation Change Detection Using Remote Sensing and Gis—A Case Study of Vellore District." *Procedia Computer Science* 57. Elsevier: 1199–1210.

(Gegout and Rossi 1994): Gegout Cédric, and Fabrice Rossi. 1994. "Initialisation Des Réseaux de Neurones Non Récurrenssa Coefficients Réels Par Algorithmes Evolutionnistes." *Journées Internationales Sur Les Réseaux Neuromimétiques et Leurs Applications*, 416–424.

(Gharib and Benhra. 2015): Gharib Abdelhakim, and Jamal Benhra. 2015. "Tuning Manuel de l'algorithme d'optimisation Par Essaims de Particules Appliqué Au Problème de Voyageur de Commerce." In *Xème Conférence Internationale: Conception et Production Intégrées*.

Références Bibliographiques

(Gherdaoui 2018): Gherdaoui Sarah. 2018. “Conception d’une Fusion Pour La Détection de Changements Sur Les Images Satellitaires.” Thèse de Doctorat, Université Mohamed Boudiaf USTO-ORAN-Algérie.

(Ghoumari 2018): Ghoumari Asmaa. 2018. “Métaheuristiques Adaptatives d’optimisation Continue Basées Sur Des Méthodes d’apprentissage.” Thèse de doctorat, Université Paris-Est, France.

(Gonenc et al 2019): Gonenc Abdurrahman, Mehmet Sirac Ozerdem, and Acar Emrullah. 2019. “Comparison of NDVI and RVI Vegetation Indices Using Satellite Images.” In *2019 8th International Conference on Agro-Geoinformatics (Agro-Geoinformatics)*, 1–4. IEEE.

(Guellil and Zaoui. 2009): Guellil Z, and Lynda Zaoui. 2009. “Proposition d’une Solution Au Problème d’Initialisation Cas Du K-Means.” In *CIIA*.

(Hachemi et al 2009): Hachemi Kamel, Abdelkader Abdellaoui, André Ozer, Florina Grecu, and Gheorghe Visan. 2009. “Apport de l’imagerie Radar SAR (Images d’Amplitude) Pour l’analyse Des Aléas et Du Changement Dans La Région de Buzău (Roumanie).” *Revista de Geomorfologie* University of Bucharest. Faculty of Geography.: 11, 63–72.

(Han et al 2015): Han XiaoHong, Xiaoyan Xiong, and Fu Duan. 2015. “A New Method for Image Segmentation Based on BP Neural Network and Gravitational Search Algorithm Enhanced by Cat Chaotic Mapping.” *Applied Intelligence* 43 (4). Springer: 855–873.

(Hannane and Fizazi 2016): Amir Mokhtar Hannane, and Fizazi Hadria. 2016. “Metaheuristics and Neural Network for Satellite Images Classification.” *International Review of Aerospace Engineering (IREASE)* 9 (4): 107–113.

(Hao and Solnon 2014): Hao Jin-Kao and Christine Solnon, 2014. “Algorithmes pour l’intelligence artificielle”, *Série Panorama de l’intelligence artificielle, Cépaduès*, (2) ,1-19.

Références Bibliographiques

(Hao et al 1999): Hao Jin-Kao, Philippe Galinier, and Michel Habib. 1999. “Métaheuristiques Pour l’optimisation Combinatoire et l’affectation Sous Contraintes.” *Revue d’intelligence Artificielle* 13 (2): 283–324.

(Hassan et al 2019): Hassan Hussein El Hage, Françoise Ardillier-Carras, and Laurence Charbel. 2019. “Les Changements d’occupation Des Sols Dans La Béqaa Ouest (Liban): Le Rôle Des Actions Anthropiques.” *Cahiers Agricultures* (28), 10.

(Hassib et al, 2020): Hassib Eslam M., et al, 2020. "WOA+ BRNN: An imbalanced big data classification framework using Whale optimization and deep neural network." *soft computing* 24. (8): 5573-5592.

(Huang et al 2018.): Huang Bo, Bei Zhao, and Yimeng Song. 2018. “Urban Land-Use Mapping Using a Deep Convolutional Neural Network with High Spatial Resolution Multispectral Remote Sensing Imagery.” *Remote Sensing of Environment* 214. Elsevier: 73–86.

(Huang and Chou. 2019): Huang Mei Ling, and Yueh Ching Chou. 2019. “Combining a Gravitational Search Algorithm, Particle Swarm Optimization, and Fuzzy Rules to Improve the Classification Performance of a Feed-Forward Neural Network.” *Computer Methods and Programs in Biomedicine* 180. Elsevier: 105016.

(Hussain et al 2013): Hussain Masroor, Dongmei Chen, Angela Cheng, Hui Wei, and David Stanley. 2013. “Change Detection from Remotely Sensed Images: From Pixel-Based to Object-Based Approaches.” *ISPRS Journal of Photogrammetry and Remote Sensing* 80. Elsevier: 91–106.

(Jeanson 2015): Jeanson Ratovoarison Didier. 2015. “Détection de changement sur l’occupation du sol à l’aide de la méthode ACP (analyse en composantes principales) et la logique floue.” Université d’antananarivo, Madagascar.

(Jensen and Im. 2007): Jensen John R, and Jungho Im. 2007. “Remote Sensing Change Detection in Urban Environments.” In *Geo-Spatial Technologies in Urban Environments*, 7–31. Springer.

Références Bibliographiques

(Jiang et al 2018): Jiang Wei, Guojin He, Tengfei Long, Yuan Ni, Huichan Liu, Yan Peng, Kenan Lv, and Guizhou Wang. 2018. “Multilayer Perceptron Neural Network for Surface Water Extraction in Landsat 8 OLI Satellite Images.” *Remote Sensing* 10 (5). Institute: 755.

(Jiang et al. 2020): Jiang Xiao, Gang Li, Yu Liu, Xiao-Ping Zhang, and You He. 2020. “Change Detection in Heterogeneous Optical and SAR Remote Sensing Images via Deep Homogeneous Feature Fusion.” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 13. IEEE: 1551–1566.

(Jourdan 2010): Jourdan Laetitia. 2010. “Métaheuristiques Coopératives: Du Déterministe Au Stochastique.” Université des Sciences et Technologie de Lille-Lille I. France.

(Karoui 2012): Karoui Moussa Sofiane. 2012. “Méthodes de Séparation Aveugle de Sources et Application à La Télédétection Spatiale.” Thèse de Doctorat, Université de Toulouse III-Paul Sabatier-France.

(Kennedy and Eberhart 1995): Kennedy James, and Russell Eberhart. 1995. “Particle Swarm Optimization.” In *Proceedings of ICNN'95-International Conference on Neural Networks*, 4: 1942-1948.

(Kergomard 1990): Kergomard Claude. 1990. “La Télédétection Aérospatiale: Une Introduction.” *Cours de Télédétection, Ecole Normale Supérieure Paris*.

(Kirkpatrick et al 1983): Kirkpatrick, Scott, C Daniel Gelatt, and Mario P Vecchi. 1983. “Optimization by Simulated Annealing.” *Science*. American association for the advancement of science: 220, (4598), 671–680.

(Kourdian 2009): Kourdian Raphaël. 2009. “Analyse de La Traficabilité En Zone Tropicale Par Imagerie Spatiale Optique et Radar: Application Au Tchad Méridional.” Thèse de doctorat, École Nationale Supérieure des Mines de Paris, France.

(Lalami 2012): Lalami Mohamed Esseghir. 2012. “Contribution à La Résolution de Problèmes d’optimisation Combinatoire: Méthodes Séquentielles et Parallèles.” Thèse de doctorat, Université Toulouse III-Paul Sabatier, France..

Références Bibliographiques

(Lang 2015): Lang Marc. 2015. “Classification Des Types de Prairies et Estimation de La Diversité Taxonomique à Partir de Séries Temporelles d’images Satellites.” Thèse de doctorat, Ecole Nationale Supérieure Agronomique de Toulouse (INPT-ENSAT), France.

(Lefebvre 2011): Lefebvre Antoine. 2011. “Contribution de La Texture Pour l’analyse d’images à Très Haute Résolution Spatiale. Application à La Détection de Changement En Milieu Périurbain,” Thèse de doctorat. Université Rennes 2, France.

(Lewis and Brown 2001): Lewis H G, and M Brown. 2001. “A Generalized Confusion Matrix for Assessing Area Estimates from Remotely Sensed Data.” *International Journal of Remote Sensing* 22 (16). Taylor & Francis: 3223–3235.

(Liu et al 2019): Liu Ruoyun, Monika Kuffer, and Claudio Persello. 2019. “The Temporal Dynamics of Slums Employing a CNN-Based Change Detection Approach.” *Remote Sensing* 11 (23).2844.

(Liu et al 2019): Liu Sicong, Daniele Marinelli, Lorenzo Bruzzone, and Francesca Bovolo. 2019. “A Review of Change Detection in Multitemporal Hyperspectral Images: Current Techniques, Applications, and Challenges.” *IEEE Geoscience and Remote Sensing Magazine* 7 (2). IEEE: 140–158.

(Lones 2014): Lones Michael A. 2014. “Metaheuristics in Nature-Inspired Algorithms.” In *Proceedings of the Companion Publication of the 2014 Annual Conference on Genetic and Evolutionary Computation*, 1419–1422.

(Lu et al 2004a): Lu Dengsheng, Mateus Batistella, and Emilio Moran. 2004a. “Multitemporal Spectral Mixture Analysis for Amazonian Land-Cover Change Detection.” *Canadian Journal of Remote Sensing* 30 (1). Taylor & Francis: 87–100.

(Lu et al 2004b): Lu Dengsheng, Paul Mausel, Eduardo Brondizio, and Emilio Moran. 2004b. “Change Detection Techniques.” *International Journal of Remote Sensing* 25 (12). Taylor & Francis: 2365–2401.

(Luppino et al 2018): Luppino Luigi T, Filippo M Bianchi, Gabriele Moser, and Stian N Anfinsen. 2018. “Remote Sensing Image Regression for Heterogeneous Change

Références Bibliographiques

Detection.” In *2018 IEEE 28th International Workshop on Machine Learning for Signal Processing (MLSP)*, 1–6. IEEE.

(Lyon et al 1998): Lyon John G, Ding Yuan, Ross S Lunetta, and Chris D Elvidge. 1998. “A Change Detection Experiment Using Vegetation Indices.” *Photogrammetric Engineering and Remote Sensing* 64 (2). American Society of Photogrammetry.: 143–150.

(Mahi 2014): Mahi Habib. 2014. “Extraction de Formes Géométriques à Partir Des Données Satellitaires et Leur Intégration Dans Un Processus Classificateur Multisource.” Thèse de Doctorat, Université des sciences et de la technologie d’Oran Mohamed Boudiaf, Algérie.

(Mallucci et al 2019): Mallucci S, B Majone, and A Bellin. 2019. “Detection and Attribution of Hydrological Changes in a Large Alpine River Basin.” *Journal of Hydrology* (575). Elsevier: 1214–1229.

(Mamouni and Belkacem 2018): Mamouni Adel, and Belkacem Ould Mohamed. 2018. “Une Métaheuristique Basée Sur Le Comportement Des Lucioles Pour La Résolution d’un Problème d’ordonnancement Dans Un Atelier Flow Shop.” Thèse de doctorat, Université Abou Bekr Belkaid Tlemcen, Algérie.

(Mas 2000): Mas J F. 2000. “Une Revue Des Méthodes et Des Techniques de Télédétection Du Changement.” *Canadian Journal of Remote Sensing* 26 (4). Taylor & Francis: 349–362.

(Masse 2013): Masse Antoine. 2013. “Développement et Automatisation de Méthodes de Classification à Partir de Séries Temporelles d’images de Télédétection: Application Aux Changements d’occupation Des Sols et à l’estimation Du Bilan Carbone.” Thèse de Doctorat, Université Toulouse III-Paul Sabatier, France.

(Matese et al 2015): Matese Alessandro, Piero Toscano, Salvatore Filippo Di Gennaro, Lorenzo Genesio, Francesco Primo Vaccari, Jacopo Primicerio, Claudio Belli, Alessandro Zaldei, Roberto Bianconi and Beniamino Gioli. 2015. “Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture.” *Remote Sensing* 7 (3): 2971–2990.

Références Bibliographiques

(Mehouas 2019): Mehouas Abdallah. 2019. “Dé-Bruitage Du Signal Électrocardiogramme (ECG) Par Le Filtre de Kalman Étendu Optimisé Par l’Algorithme PSO.” Thèse de Doctorat, Université Mohamed Boudiaf Msila, Algérie.

(Meignan 2008): Meignan David. 2008. “Une Approche Organisationnelle et Multi-Agent Pour La Modélisation et l’implantation de Métaheuristiques, Application Aux Problèmes d’optimisation de Réseaux de Transports.” Thèse de doctorat, Université de Technologie de Belfort-Montbéliard, France.

(Mendonça et al 2020): Mendonça Márcio, Rodrigo H C Palácios, Elpiniki I Papageorgiou, and Lucas Botoni de Souza. 2020. “Multi-Robot Exploration Using Dynamic Fuzzy Cognitive Maps and Ant Colony Optimization.” In *2020 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, 1–8.

(Metropolis et al 1953): Metropolis Nicholas, Arianna W Rosenbluth, Marshall N Rosenbluth, Augusta H Teller, and Edward Teller. 1953. “Equation of State Calculations by Fast Computing Machines.” *The Journal of Chemical Physics* 21 (6). American Institute of Physics: 1087–1092.

(Minu and Amba 2015): Minu S and Amba Shetty. 2015. “A Comparative Study of Image Change Detection Algorithms in Matlab.” *Aquatic Procedia* (4). Elsevier: 1366–1373.

(Mirjalili et al 2012): Mirjalili SeyedAli, Siti Zaiton Mohd Hashim, and Hossein Moradian Sardroudi. 2012. “Training Feedforward Neural Networks Using Hybrid Particle Swarm Optimization and Gravitational Search Algorithm.” *Applied Mathematics and Computation* 218 (22). Elsevier: 11125–11137.

(Mouissa et al 2018): Mouissa Habib, Richard A Fournier, El-Hadi Oldache, and Mohammed Bellatreche. 2018. “Détection Des Changements Au Niveau d’un Couvert Forestier En Milieu Semi-Aride Entre 1984–2009: Cas de La Forêt de Senalba Chergui de Djelfa (Algérie).” *Canadian Journal of Remote Sensing* 44 (2). Taylor & Francis: 113–130.

Références Bibliographiques

(Mouri 2020): Mouri Hayat. 2020. “Méthode Des Contours Actifs Pour La Détection Dans Les Images Remerciements.” Thèse de doctorat, Université Mohamed Boudiaf Oran- USTO, Algérie.

(Mousselm and Cherifa, 2020): Mousselm el Zohra and Cherifa Houtia, 2020. “Détection Des Changements Dans Les Images Satellitaires.” Mémoire de Master , Université Ahmed Draia Adrar, Algérie.

(Msaaf and Fouad 2015): Msaaf Mohammed, and Fouad Belmajdoub. 2015. “L’application Des Réseaux de Neurone de Type «feedforward» Dans Le Diagnostic Statique.” In *Xème Conférence Internationale: Conception et Production Intégrées*.

(Nemmour 2003): Nemmour Hassiba. 2003. “Méthodes de Détection de Changement Dans Les Images Optiques de Télédétection.” Thèse de doctorat, Université Houari Boumediene Alger, Algérie.

(Nouicer 2014): Nouicer Imene. 2014. “Optimisation Des Réseaux de Neurones Par l’AIS Pour Le Traitement Des Données Optiques.” Mémoire de Magister , Université Mohamed Boudiaf des sciences et de la technologie d’Oran, Algérie.

(Ottavianelli and Fabio 2018): Ottavianelli Giuseppe, and Fabio D Vescovi. 2018. “Harmonisation of Optical Product Types in Relation to Geometric Corrections.” *Remote Sensing Letters* 9 (3). Taylor & Francis: 257–263.

(Oulmelha and Smail 2015): Oulmelha Omar, and Smail Mansour. 2015. “l’exploitation des images multi-temporelles pour la détection des changements.” Mémoire de Master , Université Abdelhamid ibn Badis Mostaganem, Algérie.

(Panuju et al 2019): Panuju Dyah R, David J Paull, and Bambang H Trisasongko. 2019. “Combining Binary and Post-Classification Change Analysis of Augmented ALOS Backscatter for Identifying Subtle Land Cover Changes.” *Remote Sensing* 11 (1). Multidisciplinary Digital Publishing Institute: 100.

Références Bibliographiques

(Patil et al 2017): Patil Sopan D, Yuting Gu, Felipe S A Dias, Marc Stieglitz, and Greg Turk. 2017. “Predicting the Spectral Information of Future Land Cover Using Machine Learning.” *International Journal of Remote Sensing* 38 (20). Taylor & Francis: 5592–5607.

(Pennober and Alice 2010): Pennober Gwenaëlle, and Alice Borius. 2010. “Détection à Très Haute Résolution Spatiale Du Blanchissement Corralien Sur Les Récifs de l’Île de La Réunion.” *Téledétection* 9 (1): 5–17.

(Polykretis et al 2020): Polykretis Christos, Manolis G Grillakis, and Dimitrios D Alexakis. 2020. “Exploring the Impact of Various Spectral Indices on Land Cover Change Detection Using Change Vector Analysis: A Case Study of Crete Island, Greece.” *Remote Sensing* 12 (2). Multidisciplinary Digital Publishing Institute: 319.

(Pony et al 2000): Pony, Olivier, Xavier Descombes, and Josiane Zerubia. 2000. “Classification d’images Satellitaires Hyperspectrales En Zone Rurale et Périurbaine.” Thèse de doctorat. INRIA.

(Qin et al 2018): Qin Dong, Xiangmin Zhou, Weiyi Zhou, Guangyan Huang, Yongli Ren, Ben Horan, Jing He, and Naoki Kito. 2018. “MSIM: A Change Detection Framework for Damage Assessment in Natural Disasters.” *Expert Systems with Applications* 97. Elsevier: 372–383.

(Radke et al 2005): Radke Richard J, Srinivas Andra, Omar Al-Kofahi, and Badrinath Roysam. 2005. “Image Change Detection Algorithms: A Systematic Survey.” *IEEE Transactions on Image Processing* 14 (3). IEEE: 294–307.

(Ramchoun et al 2016): Ramchoun Hassan, Mohammed Amine Janati Idrissi, Youssef Ghanou, and Mohamed Ettaouil. 2016. “Multilayer Perceptron: Architecture Optimization and Training.” *IJIMAI* 4 (1): 26–30.

(Rashedi et al 2009): Rashedi, Esmat, Hossein Nezamabadi-Pour, and Saeid Saryazdi. 2009. “GSA: A Gravitational Search Algorithm.” *Information Sciences* 179 (13). Elsevier: 2232–2348.

Références Bibliographiques

(Rather and P Bala 2019): Rather Sajad Ahmad, and P. Bala Shanthi. , 2019. "Hybridization of Constriction Coefficient-Based Particle Swarm Optimization and Chaotic Gravitational Search Algorithm for Solving Engineering Design Problems." International Conference on Advanced Communication and Networking. Springer, Singapore.

(Rather and P Bala 2000): Rather Sajad Ahmad and P. Bala Shanthi. 2000. "Pratique Des Corrections Atmosphériques En Télédétection: Utilisation Du Logiciel 5S-PC." *Cybergeo: European Journal of Geography*. CNRS-UMR Géographie-cités 8504.

(Rather and P Bala 2020a): Rather Sajad Ahmad and P Bala Shanthi. 2020a. "A Hybrid Constriction Coefficient-Based Particle Swarm Optimization and Gravitational Search Algorithm for Training Multi-Layer Perceptron." *International Journal of Intelligent Computing and Cybernetics*. Emerald Publishing Limited.

(Rather and P Bala 2020b): Rather Sajad Ahmad and P Bala Shanthi. 2020b. "Analysis of Gravitation-Based Optimization Algorithms for Clustering and Classification." In *Handbook of Research on Big Data Clustering and Machine Learning*, 74–99. IGI Global.

(Renaut 2017): Renaut Didier. 2017. "Glossaire Des Instruments Spatiaux." *La Météorologie*. Association Météo et Climat.

(Restaino et al 2016): Restaino Rocco, Gemine Vivone, Mauro Dalla Mura, and Jocelyn Chanussot. 2016. "Fusion of Multispectral and Panchromatic Images Based on Morphological Operators." *IEEE Transactions on Image Processing* 25 (6). IEEE: 2882–95.

(Riffi and Fizazi 2012): Riffi Mohamed Amine, and Hadria Fizazi. 2012. "Integration of NDVI Indices from the Tasseled Cap Transformation for Change Detection in Satellite Images." *International Journal of Computer Science Issues (IJCSI)* 9 (3).172.

(Ronald et al 2009): Ronald Eastman, J, Florencia Sangermano, Bardan Ghimire, Honglei Zhu, Hao Chen, Neeti Neeti, Yongming Cai, Elia A Machado, and Stefano C

Références Bibliographiques

Crema. 2009. “Seasonal Trend Analysis of Image Time Series.” *International Journal of Remote Sensing* 30 (10). Taylor & Francis: 2721–2726.

(Rumelhart et al 1986): Rumelhart David E, Geoffrey E Hinton, and Ronald J Williams. 1986. “Learning Representations by Back-Propagating Errors.” *Nature* 323 (6088). Nature Publishing Group: 533–536.

(Sabry et al 2013): Sabri Norlina Mohd, Mazidah Puteh, and Mohamad Rusop Mahmood. 2013. “A Review of Gravitational Search Algorithm.” *Int. J. Advance. Soft Comput. Appl* 5 (3): 1–39.

(Sabry et al 2015): Sabry Ahmed Haroun, Abdelkabir Bacha, and Jamal Benhra. 2015. “Utilisation Des Réseaux de Neurones Pour Le Tuning Des Algorithmes d’optimisation Par Colonies de Fourmis Application Aux Chaines Logistiques.” In *Xème Conférence Internationale: Conception et Production Intégrées*.

(Sakurada and Takayuki 2015): Sakurada Ken, and Takayuki Okatani. 2015. “Change Detection from a Street Image Pair Using CNN Features and Superpixel Segmentation.” In *BMVC*, 61:1–12.

(Sarr 2009): Sarr Mamadou Adama. 2009. “Cartographie Des Changements de l’occupation Du Sol Entre 1990 et 2002 Dans Le Nord Du Sénégal (Ferlo) à Partir Des Images Landsat.” *Cybergeo: European Journal of Geography*. CNRS-UMR Géographie-cités 8504.

(Schwab et al 2013): Schwab Didier, Jérôme Goulian, and Andon Tchechmedjiev. 2013. “Désambiguïsation Lexicale de Textes: Efficacité Qualitative et Temporelle d’un Algorithme à Colonies de Fourmis.” *Traitement Automatique Des Langues* 54 (1).

(Semchedine 2018): Semchedine, Moussa. 2018. “Contribution à La Segmentation d’images Médicales Par Les Algorithmes Bio-Inspirés.” Thèse de doctorat, Université Ferhat Abbas–Sétif, Algérie.

(Sheikhan and Jadidi 2014): Sheikhan Mansour, and Zahra Jadidi. 2014. “Flow-Based Anomaly Detection in High-Speed Links Using Modified GSA-Optimized Neural Network.” *Neural Computing and Applications* 24 (3). Springer: 599–611.

Références Bibliographiques

(Si Salah 2019): Si Salah Hayet, Samy Ait-Aoudia, Abdelmounaam Rezgui, and Sally E Goldin. 2019. “Change Detection in Urban Areas from Remote Sensing Data: A Multidimensional Classification Scheme.” *International Journal of Remote Sensing* 40 (17). Taylor & Francis: 6635–6679.

(Singh 1989): Singh Ashbindu. 1989. “Review Article Digital Change Detection Techniques Using Remotely-Sensed Data.” *International Journal of Remote Sensing* 10 (6). Taylor & Francis: 989–1003.

(Solaiman and Lepage 2003): Solaiman Basel, and Lepage Richard. 2003. *Les Réseaux de Neurones Artificiels et Leurs Applications En Imagerie et En Vision Par Ordinateur*. Presse Universitaire du Québec.

(Solly 2021): Solly Boubacar, Oumar Sy, Aruna M Jarju, and Tidiane Sané. 2021. “Détection Des Zones de Dégradation et de Régénération de La Couverture Végétale Dans Le Sud Du Sénégal à Travers l’analyse Des Tendances de Séries Temporelles MODIS NDVI et Des Changements d’occupation Des Sols à Partir d’images LANDSAT.” *Revue Française de Photogrammétrie et de Télédétection* 223: 1–15.

(Solofo 2019): Solofo pr Rakotondraompiana. 2019. “classification typologique des ecosistemés utilisés dans les légendes des cartes d’occupation du sol de madagascar.” Thèse de doctorat, Université d’Antananarivo, Madagascar.

(Song et al 2021): Song Wei, Minghui Li, Wen Gao, Dongmei Huang, Zhenling Ma, Antonio Liotta, and Cristian Perra. 2021. “Automatic Sea-Ice Classification of SAR Images Based on Spatial and Temporal Features Learning.” *IEEE Transactions on Geoscience and Remote Sensing*. IEEE.

(Soon et al 2018): Soon Foo Chong, Hui Ying Khaw, Joon Huang Chuah, and Jeevan Kanesan. 2018. “Hyper-Parameters Optimisation of Deep CNN Architecture for Vehicle Logo Recognition.” *IET Intelligent Transport Systems* 12 (8). IET: 939–946.

(Sun et al 2018): Sun Hua, Qing Wang, Guangxing Wang, Hui Lin, Peng Luo, Jiping Li, Siqi Zeng, Xiaoyu Xu, and Lanxiang Ren. 2018. “Optimizing KNN for Mapping

Références Bibliographiques

Vegetation Cover of Arid and Semi-Arid Areas Using Landsat Images.” *Remote Sensing* 10 (8). Multidisciplinary Digital Publishing Institute: 1248.

(Sylla 2014): Sylla Diogone. 2014. “Fusion de Données Provenant de Différents Capteurs Satellitaires Pour Le Suivi de La Qualité de l’eau En Zones Côtières. Application Au Littoral de La Région PACA.” Thèse de doctorat, Toulon, France.

(Tamminga et al 2015): Tamminga A, C Hugenholtz, B Eaton, and M Lapointe. 2015. “Hyperspatial Remote Sensing of Channel Reach Morphology and Hydraulic Fish Habitat Using an Unmanned Aerial Vehicle (UAV): A First Assessment in the Context of River Research and Management.” *River Research and Applications* 31 (3). 379–391.

(Tekkouk and Fizazi 2019): Aicha Tekkouk and Fizazi Hadria. 2019. “Classification of Clouds by the Eagle Strategy.” *International Review of Aerospace Engineering (IREASE)* 12 (3): 123–130.

(Tounsi 2017): Tounsi Farouk. 2017. “Optimisation d’entraînement Des Réseaux de Neurones RBF Par La Métaheuristique ACO.” Mémoire de master, Université Larbi Ben M’hidi Oum El Bouaghi, Algérie.

(Tu Yu et al 2018): Tu Yu-Hsuan, Stuart Phinn, Kasper Johansen, and Andrew Robson. 2018. “Assessing Radiometric Correction Approaches for Multi-Spectral UAS Imagery for Horticultural Applications.” *Remote Sensing* 10 (11). Multidisciplinary Digital Publishing Institute: 1684.

(Wan et al 2019): Wan Ling, Yuming Xiang, and Hongjian You. 2019. “A Post-Classification Comparison Method for SAR and Optical Images Change Detection.” *IEEE Geoscience and Remote Sensing Letters* 16 (7). IEEE: 1026–1030.

(Wang et al 2018): Wang Zhongrui, Saumil Joshi, Sergey Savel’ev, Wenhao Song, Rivu Midya, Yunning Li, Mingyi Rao, Peng Yan, Shiva Asapu, and Ye Zhuo. 2018. “Fully Memristive Neural Networks for Pattern Classification with Unsupervised Learning.” *Nature Electronics* 1 (2). Nature Publishing Group: 137–145.

Références Bibliographiques

(Widmer 2001): Widmer Marino. 2001. “Les Métaheuristiques: Des Outils Performants Pour Les Problèmes Industriels.” In *3ème Conférence Francophone de MOdélisation et SIMulation MOSIM*, 1:25–27.

(Zhang et al 2019): Zhang Aizhu, Sihan Liu, Genyun Sun, Hui Huang, Ping Ma, Jun Rong, Hongzhang Ma, Chengyan Lin, and Zhenjie Wang. 2019. “Clustering of Remote Sensing Imagery Using a Social Recognition-Based Multi-Objective Gravitational Search Algorithm.” *Cognitive Computation* 11 (6). Springer: 789–798.

(Zhang and Hu. 2020): Zhang Yanghua, and Hu Zhao. 2020. “Land–use and Land-Cover Change Detection Using Dynamic Time Warping–based Time Series Clustering Method.” *Canadian Journal of Remote Sensing* 46 (1). Taylor & Francis: 67–83.

(Zhao et al 2021): Zhao Rui, Guo-Hua Peng, Wei-dong Yan, Lu-Lu Pan, and Li-Ya Wang. 2021. “Change Detection in SAR Images Based on Superpixel Segmentation and Image Regression.” *Earth Science Informatics* 14 (1). Springer: 69–79.

(Zheng and Ren 2020): Zheng Hao, and Yue Ren. 2020. “Architectural Layout Design through Simulated Annealing Algorithm.” 25th International Conference of the Association for Computer-Aided Architectural Design Research in Asia (CAADRIA), (1), 275-284.

(Zidane 2018): Zidane Fodhil. 2018. “Détermination Des Vitesses Minimales de Fluidisation et Des Regi Mes Découlement En Fluidisation Triphasique Gaz-Liquidesolide.” Thèse de doctorat, Université de Setif, Algerie.