



République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



Université Amar Telidji-Laghouat

FACULTE: DE TECHNOLOGIE

DEPARTEMENT :

D'ELECTRONIQUE

DOMAINE : Science et Technologies

FILIERE : ELECTRONIQUE

OPTION : ELECTRONIQUE DES SYSTEMES EMBARQUES

MEMOIRE DE MASTER

Réalisé par :

Horma Abdelaziz

&

Mokhtari Taher Hadjaissa

Thème

**Etude comparative des méthodes de
segmentation automatique des images
satellitaires en vue de la détection des eaux.**

Jury de soutenance :

Nom et Prénom	Grade	Qualité
Mr Mourad Reguigue	MCB	Président
Mr Abdelkader Birame	MCB	Examineur
Mme Fatiha Benkouider	MCB	Encadreur

Promotion : 2023/2024

Remerciements

La réalisation de ce mémoire a été possible grâce à la collaboration de plusieurs personnes à qui je voudrais témoigner toute ma gratitude.

Nos reconnaissances et gratitude vont tout d'abord à Madame Benkouider Fatiha, notre directrice de mémoire pour sa patience, sa disponibilité, son encadrement, son orientation et surtout ses judicieux conseils qui ont contribué à alimenter notre réflexion.

Nos remerciements aux professeurs du département d'électronique de l'université de Ammar Telidji de Laghouat qui ont contribué à notre formation.

Nous remercions les membres du jury d'avoir accepté de juger notre travail.

Un grand merci à nos parents pour leurs conseils, aides morale et matériels, ils ont grandement facilité notre travail, merci à nos sœurs.

Nous exprimons notre reconnaissance envers les amis et collègues qui nous ont apporté leur soutien moral et intellectuel tout au long de notre démarche.

À tous ces intervenants, nous présentons nos remerciements, nos respect et notre gratitude.

Abdelaziz Horma et Mohamed Taher Mokhtari



Dédicace

Je dédie ce modeste travail au meilleur des pères et à ma très chère maman qu'ils trouvent en moi la source de leur fierté qui ne cessent de me donner avec amour le nécessaire pour que je puisse arriver à ce que je suis aujourd'hui.

Que dieu les protège et que la réussite soit toujours à ma portée pour que je puisse vous combler de bonheur.

À mes sœurs et mes frères,

À toute ma famille et à tous mes amies,

A tous les gens qui me connaissent et que je connais en particulier ,

À tous ceux qui me sont chers, aux personnes qui m'ont aidé et encouragé de près ou de loin, qui étaient toujours à mes côtés et qui m'ont accompagné durant mon chemin d'études.

Aziz Horma

Dedicace

Tout d'abord, je tiens à remercier Dieu tout puissant de m'avoir donné la force et le courage de mener à bien ce modeste travail.

Je tiens à dédier cet humble travail à : A ma tendre mère Mamma,

A mes sœur: Narimane, Nacera et Maria

A mon binôme Horma Abdelaziz

A mes meilleurs amis : Kadi , Dadi , Aziz et Salman

Tout ceux qui m'aiment et que j'aime

Mohamed Taher Mokhtari

ملخص

تستهدف عملية الكشف عن المياه عن طريق الصور الفضائية الى رسم الخرائط ومراقبة المسطحات المائية على الصعيدين الإقليمي والدولي. تعد مراقبة وإدارة موارد المياه، واكتشاف الفيضانات، ودراسة التغيرات المناخية، وتحليل البيئة، وما إلى ذلك، من الأهداف الرئيسية. ان لاستخدام الصور الفضائية للحصول على رؤية شاملة وتغطية

مكانية واسعة النطاق، مما يسمح بتحليل واسع النطاق وطويل الأجل لخصائص المياه على الأرض. يحاول هذا البحث استخراج مناطق المياه من خلال ثلاث طرق للتجزئة المراقبة: الشبكات العصبية الاصطناعية (RNA)، وآلات الدعم المتجهة (SVM)، وأقرب الجيران (KPP)، مع تقديم تحليل نقدي لهذه الأساليب وفحص فعاليتها وقوتها.

الكلمات المفتاحية: تجزئة الصور: الشبكات العصبية الاصطناعية، آلات المتجهات الداعمة، k أقرب جيران؛ صورة الأقمار الصناعية؛ الكشف عن المياه

Résumé

La détection d'eau à partir d'images satellitaires vise à cartographier et surveiller les étendues d'eau à l'échelle régionale ou internationale. La surveillance et la gestion des ressources en eau, la détection des inondations, l'étude des changements climatiques, l'analyse de l'environnement, etc., sont parmi les objectifs principaux. Afin d'accomplir ces objectifs, on utilise les images satellitaires afin d'obtenir une vision globale et une couverture spatiale étendue, ce qui permet une analyse à grande échelle et à long terme des caractéristiques aquatiques de la Terre. Ce mémoire tente d'extraire les zones d'eau par trois méthodes de segmentation supervisée: les réseaux de neurones artificiels (RNA), les machines à vecteurs de support (SVM) et les k plus proches voisins (KPP) tout en offrant une analyse critique de ces méthodes et une examination de leurs efficacités et leurs robustesses .

Mots clés : Segmentation d'image : Réseaux de neurones artificiels, Machines à vecteurs de support, K plus proches voisins ; Image satilitale ; Détection d'eau

Abstract

Water detection from satellite images aims to map and monitor water bodies on a regional or international scale. Monitoring and management of water resources, flood detection, study of climate changes, environmental analysis, etc., are among the main objectives. To accomplish these goals, satellite images are used to provide global vision and extensive spatial coverage, enabling large-scale, long-term analysis of the Earth's aquatic features. This thesis attempts to extract water areas and examines by three supervised segmentation methods: artificial neural networks (ANN), support vector machines (SVM) and k nearest neighbors (KNN) providing a critical analysis of these methods and an examination of their effectiveness and robustness.

Keywords: Image Segmentation: Artificial Neural Networks, Support Vector Machines, K Nearest Neighbors; Satellite image; Water detection

v

Sommaire

Introduction Générale	XII
CHAPITRE I Généralité sur l'image.....	<u>3</u>
I.1 Introduction	4
I.2 Définition d'une image	4
I.3 Image numérique	4
I.4 Caractéristiques de l'image numérique	5
I.5 Les différents types d'images numériques	9
I.6 Acquisition d'une image	11
I.7 L'image satellitale	12
I.7.1 Généralité sur les images satellitaires	12
I.7.3 Image panchromatique.....	14
I.7.4 Image multispectrale (multi-bande)	15
I.8 Traitement d'images numériques.....	15
I.9 Propriétés des pixels	15
I.10 Opérations de traitement d'images	17
I.19.4 Binarisation.....	19
I.11 conclusion.....	19
CHAPITRE II Segmentation des images.....	<u>20</u>
II.1 Introduction	21
II.2 Méthode de classification	21
II.3 Les réseau de neurones artificiels (RNA)	23
II.4 Machines à vecteur support.....	28

II.4.8 Étapes de l'algorithme SVM pour la classification: cas 1 contre le reste	39
II.5 Méthode K plu proches voisins.....	40
II.6 Conclusion	44
CHAPITRE III Résultats et Interprétations.....	<u>45</u>
III.1 Introduction.....	47
III.2 Objectifs de la détection d'eau à partir d'images satellitaires	47
III.3 Image satellitaire	48
III.4 pretraitements	50
III.5 Avantage des traitements en télédétection.....	51
III.6 Base de Données	51
III.7 Evaluation de la pression.....	52
III.8 Résultats et interprétations	54
III.9 Conclusion	66
Conclusion générale.....	67
Référence	67

Liste des figures

Titre de la figure	Page
Figure I.1 La lettre A affichée comme un groupe de pixels.....	03
Figure I.2 Image avec Luminosité modifié.....	04
Figure I.3 Image originale(a) et image améliorée par modification du contraste (b).....	05
Figure I.4 Image avec son propre histogramme.....	08
Figure I.5 Une image binaire et les valeurs de pixels dans un voisinage de 6×6 ...	09
Figure I.6 Une image en niveaux de gris et les valeurs de pixels dans un voisinage de 6×6	10
Figure I.7 Représentation en cube de l'espace de couleur RVB.....	10
Figure I.8 représentation matricielle d'une image couleur.....	11
Figure I.9 Système d'acquisition d'images.....	12
Figure I.10 Image satellitaire « Oran » (LANDSAT 5 -TM).....	13
Figure I.11 Démonstration de la résolution.....	14
Figure I.12 Image Panchromatique.....	15
Figure I.13 Image multi-bande.....	16
Figure I.14 Concept de voisinage du pixel	17
Figure I.15 Image sharpening.....	18
Figure I.16 enlèvement de bruit d'une image.....	18
Figure I.17 suppression de flou d'une image.....	19
Figure I.18 Binarisation d'une image.....	19
Figure II. 1 Représentation du neurone biologique et du neurone formel.....	24
Figure II.2 Modélisation d' un neurone artificiel.....	25
Figure II.3 Exemple d' un réseau de neurones artificiel.....	25
Figure II.4 Deux types de perceptrons.....	27
Figure II.6 SVM binaires.....	31

Figure II.7 Classification avec la machine à vecteurs de support.....	35
Figure II.8 SVM binaire à marge souple.....	36
Figure II.9 Architecture d'une machine à vecteur support [29].....	38
Figure II.10 Approche une-contre-reste avec des zones d'indécision.....	38
Figure II.11 Approche une-contre-une.....	43
Figure II.1 Fonctionnement de l'algorithme k-NN.....	43
Figure III.1 Image satellitaire « Oran » (LANDSAT 5 -TM).....	48
Figure III.2 Capteur actif et passif.....	49
Figure III.3 Démonstration de la résolutionspatiale.....	50
Figure III.3 Structure de réseau de neurones artificiel utilisé.....	
Figure III.3 Résultat de la segmentation par RNN (image 182).....	54
Figure III. 4 Performance de la classifiction (image 182).....	57
Figure III.5 Résultat de la segmentation par RNA (image 182).....	58
Figure III.6 Performance de la segementation	58
Figure III.7 Résultat de la segmentation par RNA (image 182).....	59
Figure III.8 Performance de la segementation	60
Figure III.9 Résultat de la segmentation par SVM (image 182).....	60
Figure III.10 Résultat de la segmentation par SVM (image 182).....	63
Figure III.11 Résultat de la segmentation par SVM (image 182).....	63
Figure III.12 Les métriques pour l'image 182.....	64
Figure III.13 Les métriques pour l'image 103.....	65
Figure III.14 Les métriques pour l'image 102.....	65

Liste des tables

Titre de la tables	Page
Tableau III.1 Métriques de la méthode RNA.....	58
Tableau III.2 Métriques de la méthode SVM.....	61
Tableau III Métriques de la méthode KPPV.....	63
Tableau III.4 Récapitulation des métriques.....	64

Liste des abréviations

SVM Support Vector Machine

RNA Réseaux de Neurones Artificiels

KPPV K Plus Proche Voisins

Introduction Générale

Introduction Générale

L'objectif de la détection d'eau à partir d'images satellitaires est généralement de cartographier et de surveiller les étendues d'eau à l'échelle régionale ou mondiale. Les objectifs principaux sont nombreuses on cite: la surveillance et la gestion des ressources en eaux [1], la détection des inondations [2], l'étude des changements climatiques [3], analyse environnementale, ect.

Pour atteindre ces objectifs, les images satellitaires sont utilisées pour obtenir une vue d'ensemble et une couverture spatiale étendue, ce qui permet une analyse à grande échelle et à long terme des caractéristiques aquatiques de la Terre.

L'analyse et la segmentation d'images constituent des piliers essentiels de l'informatique visuelle et de l'intelligence artificielle, offrant des solutions variées et efficaces pour traiter le contenu visuel dans divers domaines d'application tels que la médecine, la surveillance et l'industrie [4]. La segmentation d'image vise à partitionner une image en régions significatives et homogènes, facilitant ainsi l'extraction de caractéristiques et la compréhension du contenu visuel.

Traditionnellement, les méthodes de segmentation d'image reposent sur des algorithmes comme la détection de contours ou les approches par seuillage, offrant des solutions efficaces dans de nombreux cas [5]. Cependant, l'évolution rapide des techniques d'apprentissage automatique a ouvert de nouvelles avenues pour améliorer la précision et la flexibilité de la segmentation d'image.

Dans ce contexte, ce mémoire essaye de détecter les eaux et explore l'application de trois techniques de segmentation supervisée: les réseaux de neurones artificiels (RNA), les machines à vecteurs de support (SVM), les k plus proches voisins (KPP). Chaque approche présente ses propres avantages et défis, offrant une palette variée d'outils pour traiter différents types de données et de problèmes de segmentation.

Introduction Générale

Les RNA, grâce à leur capacité à apprendre des représentations hiérarchiques et à modéliser des relations non linéaires complexes, offrent une flexibilité supplémentaire dans la segmentation d'images [6]. Les SVM sont reconnues pour leur capacité à construire des frontières de décision complexes dans des espaces de haute dimension [7], tandis que les KNN se distinguent par leur simplicité et leur capacité à capturer des structures locales dans les données [8, 9].

Ce mémoire propose d'évaluer empiriquement ces techniques appliquées à la segmentation d'image, en mettant l'accent sur leurs performances comparatives, leur adaptabilité aux images satellitaires et leur potentiel pour l'amélioration des résultats par rapport aux approches traditionnelles. L'objectif est de fournir une analyse critique de ces méthodes, en examinant leur efficacité, leur robustesse.

Ce mémoire s'articule autour de trois chapitres :

- Une introduction générale,
- Le premier chapitre présente un état de l'art sur les méthodes de segmentation des images.
- Le deuxième chapitre présente la méthodologie suivie pour l'extraction de l'eau ainsi que les algorithmes utilisés.
- Le troisième chapitre présente la discussion des différents résultats obtenus et la discussion concernant les trois méthodes. Les tests sont effectués sur la base de données
- Enfin, une conclusion générale, qui est une vue globale et synthétique de notre travail.

CHAPITRE I

Généralité sur l'image

I.1 Introduction

Le développement du traitement d'image et de la vision par ordinateur a été motivé par le besoin d'extraire et d'interpréter l'ensemble des informations portées par l'image.

Dans ce chapitre nous présentons quelques notions de base du domaine de traitement d'image tels que : la définition d'image, les types d'image, caractéristiques d'image, système de traitement d'image, analyse élémentaire, filtrage, convolution, segmentation et en fin quelques exemples concrets de traitement d'images.

I.2 Définition d'une image

L'image est une représentation d'une personne ou d'un objet par la peinture, le dessin, la photographie, le film, etc. C'est aussi un ensemble structuré d'informations qui, après affichage sur l'écran, ont une signification pour l'œil humain.

Elle peut être décrite sous la forme d'une fonction $I(x, y)$ analogique continue, définie dans un domaine borné, tel que x et y sont les coordonnées spatiales d'un point de l'image et I est une fonction d'intensité lumineuse et de couleur. Sous cet aspect, l'image est inexploitable par la machine, ce qui nécessite sa numérisation [10].

I.3 Image numérique

On se basant sur la présentation en niveaux de gris, l'image numérique peut être vu comme une matrice de deux dimension (2D), dont chaque point "pixel" est caractérisé par une position x, y et une intensité lumineuse donnée par $f(x, y)$.

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots f(0,N-1) \\ f(1,0) & f(1,1) & \dots f(1,N-1) \\ \dots & \dots & \dots \\ f(M-1,0) & f(M-1,1) & \dots f(M-1,N-1) \end{bmatrix} \quad (I.1)$$

I.4 Caractéristiques de l'image numérique

Comme nous l'avons vu, l'image est un ensemble structuré d'informations parmi ses caractéristiques nous citons :

I.4.1 Pixel

Également dit en anglaise " Picture Elements " : est le plus petit élément de l'image. Si le "bit" est la plus petite unité d'information que peut traiter un ordinateur, le pixel est le plus petit élément que l'on peut manipuler sur ordinateurs. La lettre A, par exemple, peut être affichée comme un groupe de pixels dans la figure ci-dessous.




Figure I.1 La lettre A affichée comme un groupe de pixels

I.4.2 Luminosité

La luminosité d'une image en niveaux de gris est formellement décrite comme l'intensité moyenne résultant de tous les pixels de l'image. Visuellement, nous pouvons observer à quel point une image est claire ou sombre. De plus, la luminosité est liée à la distribution des valeurs d'intensité. Il est possible de modifier facilement la luminosité d'une image en ajoutant ou en soustrayant

directement une constante à chaque pixel. Par exemple, une fonction homogène qui ajoute la quantité "L" à chaque pixel engendra une augmentation de la luminosité :

$$g(f(x, y)) = f(x, y) + L \quad (I.2)$$

Cependant, les limites d'intensité de l'image doivent être prises en compte pour éviter la saturation (la saturation se produit lorsque les valeurs des pixels dépassent les limites possibles) [11]. La figure (I.2) représente un exemple de modification de luminosité.



Figure I.2 Image avec Luminosité modifié

I.4.3 Contraste

Le contraste est la différence entre la valeur d'intensité minimale et maximale présente sur l'image. Selon ce concept, une image peut être considérée comme ayant un contraste complet lorsqu'elle comporte des valeurs d'intensité de 0 et 255. Le contraste peut être définie de plusieurs façons:

- *Ecart type des variations des niveaux de gris dans l'image :*

$$C = \sqrt{\frac{1}{MN} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} (I(i, j) - \text{moy})^2} \quad (I.3)$$

Avec N et M sont respectivement le nombre de ligne et de colonne de l'image I. et moy est la valeur moyenne des pixels de l'image.

- *Variation entre valeurs de niveaux de gris min et max dans l'image*

Cette variation entre valeurs de niveaux de gris min et max dans l'image mesure relative des différences dans l'image

$$C = \frac{\max(f(x,y)) - \min(f(x,y))}{\max(f(x,y)) + \min(f(x,y))}$$

(I.4)




Figure I.3 Image originale (a) et image améliorée par modification du contraste (b)

I.4.4 Plage dynamique

La plage dynamique d'une image est définie par la taille du vecteur des niveaux d'intensité utilisés pour sa représentation. Habituellement, une image a une bonne plage dynamique lorsqu'elle est représentée avec l'ensemble complet des niveaux possibles [0, 255]. Une image d'une bonne qualité si elle a un histogramme qui couvre la plupart des niveaux de gris pour un codage sur 8 bits.

I.4.5 Histogramme

Les histogrammes d'intensité d'image jouent un rôle central dans le traitement d'image, dans des domaines tels que l'amélioration, la compression,

la segmentation et la description. Un histogramme d'une image numérique avec L niveaux d'intensité possibles au total dans la plage $[0, L]$ est défini comme la fonction discrète.

$$h(r_k) = n_k \quad (\text{I.3})$$

Où r_k est le k -ième niveau d'intensité dans l'intervalle $[0, L]$ et n_k est le nombre de pixels dans l'image dont le niveau d'intensité est r_k . La valeur de L généralement utilisée est 255 [12].

Un histogramme normalisé peut être défini comme :

$$p(r_k) = \frac{h(n_k)}{n} = \frac{n_k}{n} \quad (\text{I.4})$$




Figure I.4 Image avec son propre histogramme

I.4.6 Histogramme couleur

Étant donné que les images en couleur sont principalement représentées comme la composition de trois plans de couleur "R.V.B", donc chaque plan ou canal a un histogramme est associé et indiquant la fréquence d'occurrence de chaque intensité de couleur. De plus, la contribution de chaque pixel sur chaque canal peut être moyennée pour former une image en niveaux de gris. L'histogramme associé à la représentation en niveaux de gris d'une image en couleur peut prendre le nom d'histogramme de luminosité [11].

I.5 Les différents types d'images numériques

I.5.1 Les images noir et blanc (monochrome)

- **Les images binaires**

Les images binaires sont généralement codées sur 1 bit par pixel, où un 0 signifie généralement

«noir ou absence totale de la lumière» et un 1 signifie «blanc ou présence totale de la lumière». Généralement cette représentation est mieux adaptée aux images contenant des graphiques simples ou des textes (figure 1.5).

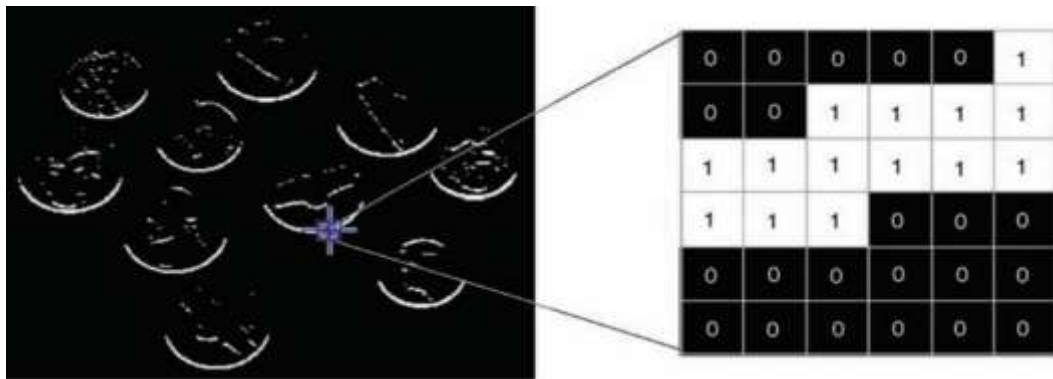


Figure I.5 Une image binaire et les valeurs de pixels dans un voisinage de 6×6

- **Les images en niveaux de gris**

Contrairement au image binaires, les images en niveaux de gris sont codées sur 8 bits, où les valeurs des pixels sont comprise entre 0, qui correspond la couleur «noir», et 255 qui correspond ala couleur «blanche», les valeurs intermédiaires indiquent les différentes nuances de gris [12], (voir figure I.6).




Figure I.6 Une image en niveaux de gris et les valeurs de pixels dans un voisinage de 6×6

I.5.2 les images couleur

La représentation la plus utilisée des images en couleur sur un système numérique est le modèle RGB, qui est construit avec la combinaison des couleurs primaires Rouge, Vert et Bleu.

Le blanc et le gris ou les nuances de gris sont produits de la même manière que les autres couleurs, par la combinaison des trois couleurs primaires RGB correspondantes. Chaque couleur possible générée par le modèle RGB peut être représenté par un cube sur le plan (R, G, B), où les intensités de chaque couleur étant généralement normalisées entre [0, 255] [11], figure 1.7.

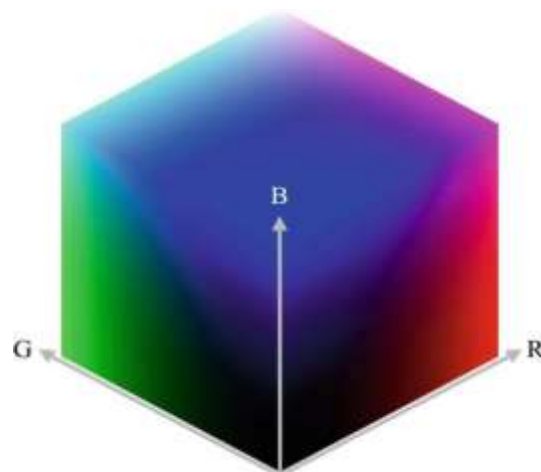


Figure I.7 Représentation en cube de l'espace de couleur RVB

Chaque pixel a une correspondance spatiale sur chaque plan (R, G, B), où chacun des éléments $R(x, y)$, $G(x, y)$ et $B(x, y)$ contient les valeurs des intensités de chaque couleur séparément. La combinaison des trois couleurs codées sur 8-bits résulte un nombre code sur 24-bits permet de représenter $2^{24} = 16777216$ couleurs, figure I.8.




Figure I.8 représentation matricielle d'une image couleur

I.6 Acquisition d'une image

Les images numériques sont générées par un capteur électronique excité par la lumière reçue. Par conséquent, une source de lumière est nécessaire pour éclairer une scène afin qu'elle puisse être capturée. La lumière réfléchiée par les objets de la scène est acquise par un capteur photosensible. Les différentes intensités lumineuses déterminent le contenu de l'image.

Le type de capteur le plus utilisé pour ce but est : C.C.D (Charged Coupled Devices) qui est composé de photo sites (éléments photo-sensibles). Chaque photosite génère une tension à son excitation, cette dernière est convertie en une valeur numérique. En fonction de la localisation spatiale

de l'élément photosensible et de l'intensité capturée une matrice de valeurs numériques est générée où chaque point correspond à un pixel de l'image numérique résultante. Chaque CCD a ses propres spécifications, mais deux caractéristiques sont souvent considérées : la résolution et la profondeur. Le nombre d'éléments photosensibles contenus dans le capteur correspond à la résolution du capteur d'images. Le processus d'acquisition d'une image numérique comprend également

une chaîne de traitement qui se résume à (l'échantillonnage, La quantification et Le codage) [11].




Figure I.9 Système d'acquisition d'images

I.7 L'image satellitale

I.7.1 Généralité sur les images satellitaires

Les images satellitaires, ou images de télédétection sont des images prises à partir d'un satellite en orbite au-dessus de la terre. Elles sont aussi nommées par des images « Remote Sensing ». Remote est le terme anglais pour désigner éloigné (ou à grande distance) et Sensing signifie sentir ou balayer. A la différence des satellites géostationnaires qui sont destinés à fournir des informations d'ordre météorologique, ou à transmettre des signaux ou des émissions de radio et de télévision, les satellites de télédétection défilent sur une orbite quasi polaire autour de la terre et assurent une couverture périodique de sa surface. Les images recueillies par ces satellites sont de type optique ou radar, selon le type de capteurs à bord, à savoir des capteurs passifs ou actifs. Elles sont transmises à des stations de réception où sont effectués les différents traitements informatiques.

Définitions

Une image satellitaire est une représentation graphique, constituée de nombreux carrés appelés pixels (figure I.10). Le pixel représente la plus petite unité figurant sur une image satellitaire, quelle que soit la longueur d'onde ou les dispositifs de télédétection qui ont été utilisés pour capter et enregistrer l'énergie électromagnétique.

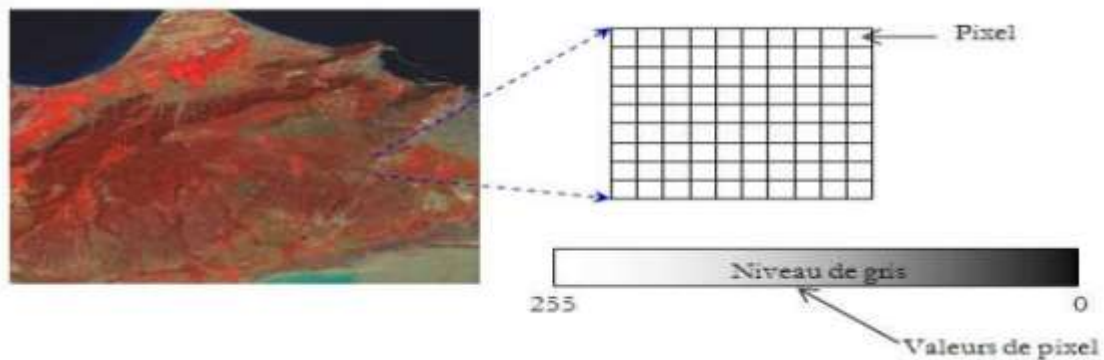


Figure I.10 Image satellitaire « Oran » (LANDSAT 5 -TM)

Afin d'obtenir des informations différentes, les capteurs observent la terre dans plusieurs bandes de longueurs d'onde, encore appelées "canaux". On dit qu'ils sont multi spectraux. A chaque pixel sont associées plusieurs valeurs radiométriques comprises entre 0 et 255. Mathématiquement c'est une fonction $F(x, y)$ à deux variables entières x et y qui sont respectivement la ligne et la colonne, fournissant une ou plusieurs valeurs entières représentant le niveau de gris du pixel dans les différents canaux, [33].

I.7.2 La résolution

Qui est la surface maximale que peut détecter un capteur dans un moment donné. On distingue :

- ***La résolution spatiale***

Elle est en fonction de la dimension du plus petit élément qu'il est possible de détecter. C'est La taille de la zone couverte par un pixel. Chaque pixel de l'image

correspond à une partie de la surface de la terre. On parle alors de "Résolution au sol" (figure I.11).



Figure I.11 Démonstration de la résolution

- **La résolution spectrale**

Elle décrit la capacité d'un capteur à utiliser de petites fenêtres de longueurs d'onde. Plus la résolution spectrale est fine, plus les fenêtres des différents canaux du capteur sont étroites. Par cette résolution, on peut distinguer plusieurs types d'images satellitaires. On cite parmi elles :

I.7.3 Image panchromatique

Elle est obtenue à partir de l'enregistrement du rayonnement électromagnétique dans un seul canal situé dans le domaine du visible. C'est une image en noir et blanc qui offre une résolution spatiale plus importante, figure I.12.

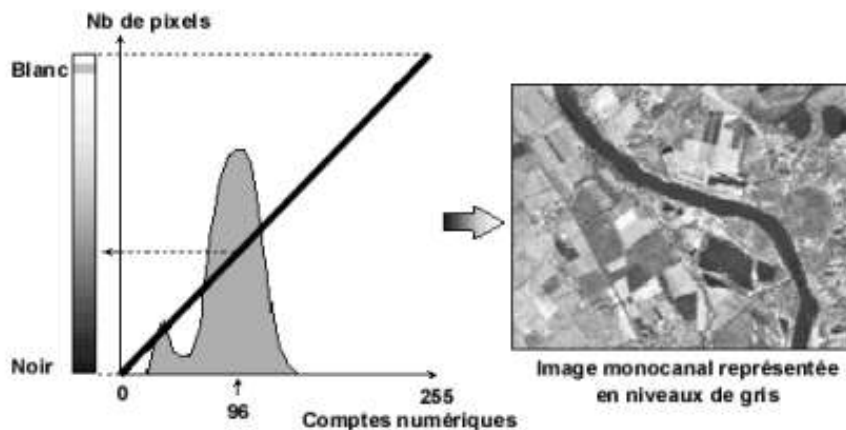


Figure I.12 Image Panchromatique.

I.7.4 Image multispectrale (multi-bande)

Elle est obtenue par des enregistrements simultanés dans un petit nombre de bandes spectrales. Ces derniers ne sont pas nécessairement contigus. La représentation par combinaison de ces bandes d'information numérique, en utilisant les trois couleurs primaires (rouge, vert, bleu) permet d'obtenir des images en couleurs, où les données de chaque bande correspondent à une couleur primaire, figure I.13.




Figure I.13 Image multi-bande.

I.8 Traitement d'images numériques

Le traitement d'images numériques peut être défini comme l'ensemble des opérations qui modifient les images numériques au moyen d'un ordinateur, ces changements sont généralement effectués soit localement ou les pixels sont traités séparément ou globalement ou tous les pixels reçoivent le même traitement. L'objectif principal du traitement d'images numériques est l'amélioration de la qualité de l'image et l'extraction des informations significatives contenues dans l'image.

I.9 Propriétés des pixels

Étant donné la nature de la représentation des images numériques, il est possible d'établir des relations entre les éléments de l'image afin d'extraire des

informations utiles en se basant essentiellement sur sa géométrie.

- **Voisinage**

Les pixels entourant un pixel donné constituent son voisinage, qui peut être interprété comme la plus petite matrice contenant le pixel de référence. La plupart des voisinages utilisés dans les algorithmes de traitement d'image sont de petits tableaux carrés avec un nombre impair de pixels.

Dans le contexte de la topologie de l'image, le voisinage prend un sens légèrement différent. Le plus courant est le 4-voisinage qui comprend soit les 4 pixels voisins ayant une relation de coteau de point (suivant la diagonale) avec le pixel de référence (p), tandis que le 8-voisinage prend en considération l'ensemble des voisins immédiats de (p). [10].




Figure I.14 Concept de voisinage du pixel p

- **Chemin**

Le chemin d'un pixel dans une image dépend de la manière dont les pixels sont stockés et organisés dans l'image. Les images numériques sont généralement composées de grilles de pixels, où chaque pixel est un petit élément d'affichage de couleur. Le chemin d'un pixel peut être déterminé en fonction de sa position dans cette grille [10].

- **Connectivité**

S'il existe un chemin à 4 entre les pixels p et q , on dit qu'ils sont

connectés à 4. De même, l'existence d'un chemin à 8 entre eux signifie qu'ils sont connectés à 8 [10].

- **Composants**

Le composant désigne une région connectée de pixels qui partagent une propriété commune, telle que la couleur ou l'intensité. Les composants peuvent être identifiés à l'aide d'algorithmes qui analysent la connectivité entre les pixels d'une image. Par exemple, dans une image binaire, les composants connectés peuvent être identifiés comme des groupes de pixels adjacents ayant la même valeur (soit 0 ou 1). Dans une image en niveaux de gris ou en couleur, les composants connectés peuvent être identifiés en fonction de la similitude des valeurs des pixels dans un certain seuil. Une fois identifiés, les composants peuvent être analysés et traités individuellement à des fins diverses, telles que la reconnaissance d'objets, la segmentation et l'extraction de caractéristiques.

I.10 Opérations de traitement d'images

I.10.1 La netteté d image "Sharpening"

L'augmentation de la netteté est une technique utilisée pour améliorer la clarté d'une image en augmentant le contraste entre les bords et les zones environnantes.



Figure I.15 Image sharpening

I.10.2 Débruitage "Noise Removal"

Le bruit d'image est un phénomène courant qui affecte les images numériques. Il peut être causé par plusieurs facteurs tels que la sensibilité du capteur, la compression de l'image et les interférences électromagnétiques.

Il existe plusieurs types de bruit d'image tels que le bruit gaussien, le bruit de poivre et sel et le bruit de speckle. Il existe plusieurs techniques de traitement d'images numériques pour enlever le bruit dans une image, notamment, le filtrage spatial et le filtrage fréquentiel. Le filtrage spatial utilise souvent un masque pour supprimer le bruit de l'image, tandis que la méthode de filtrage fréquentiel utilise la transformée de Fourier pour supprimer les fréquences correspondante au bruit dans le spectre fréquentielle de l'image.



Figure I.16 enlèvement de bruit d'une image

I.10.3 Suppression de flou "Deblurring"

"Deblurring" est une technique utilisée pour supprimer le flou d'une image. Les applications du défloutage visent l'amélioration de la qualité des images capturées dans des conditions de faible luminosité ou des images capturées avec un appareil photo de faible qualité ou encore en raison de la secousse de l'appareil photo.



Figure I.17 suppression de flou d'une image

I.19.4 Binarisation

La binarisation est la conversion d'une image avec de nombreux niveaux de gris en une image avec seulement deux niveaux de gris. Cette conversion est généralement effectuée en comparant l'intensité de chaque pixel à une valeur de référence (seuil) et en le remplaçant par une valeur qui signifie "blanc" ou "noir" en fonction du résultat de la comparaison. Où $f(x, y)$ définit l'image d'entrée et $g(x, y)$ définit l'image de sortie tandis que T est la valeur de référence dite également Seuil.




Figure I.18 binarisation d'une image

I.11 Conclusion

Dans ce chapitre nous avons introduit quelque généralité sur l'image, également nous avons mis l'accent sur certaines opérations de base du traitement d'image visent l'amélioration de sa qualité d'une part ou pour des fins d'extraction des information utiles véhiculé par l'image numériques d'autre part.

CHAPITRE II

Segmentation des images

II.1 Introduction

La segmentation consiste à découper l'image en pâties regroupant les éléments de l'image appartenant à la même classe. Le but de l'opération consiste à réaliser le découpage optimal tout en rangeant par classes, par catégories des objets avec des propriétés communes.

L'intelligence artificielle est une discipline scientifique recherchant des méthodes de solution de problèmes à forte complexité logique ou algorithmique. L'apprentissage automatique champ d'étude de l'intelligence artificielle. C'est dans cette optique que l'utilisation des méthodes de segmentation automatique telles que le réaux de neurone artificielles, les vecteurs à supports machine et le k plus proches voisin sont utilisées, ces trois méthodes vont être l'objet de notre travail.

II.2 Méthode de classification

Il existe deux catégories de classification : classification supervisée et classification non supervisée. Dans la première catégorie, les méthodes consistent à classer les objets à partir d'une base de données dite d'apprentissage, tandis que dans l'autre les méthodes classent les objets sans besoin de cette base de données.

II.2. La classification non dirigée (non supervisée)

L'opérateur ne dispose d'aucune information sur la zone d'intérêt ou ne souhaite pas en exploiter

dans la phase initiale d'analyse. Aucune information externe à l'image n'est donc introduite. Le classement des pixels est effectué uniquement selon le critère de la ressemblance spectrale.

L'étiquetage thématique est réalisé, s'il est souhaité, après la classification par interprétation des classes spectrales produites [12].

II.2.2. La classification dirigée (supervisée)

Elle pourrait aussi être dénommée classification par échantillonnage. L'opérateur a défini au préalable les classes thématiques qu'il souhaite extraire de l'image et

identifié quelques zones de l'image occupées, sans ambiguïté, par les classes d'intérêt. De ces zones, il extrait les signatures spectrales pour chaque classe. Dans la pratique, lors d'une classification d'une image comportant de nombreuses catégories d'occupation du sol, l'analyste exploite souvent une combinaison des deux procédures. La démarche est itérative jusqu'à ce que les résultats soient conformes aux objectifs fixés par l'analyste.

Marche à suivre pour une classification supervisée

La marche à suivre pour procéder à une classification dirigée comporte 10 étapes formulées ici selon une adaptation de celle proposée par Bonn et Rochon [13] :

1. Formuler avec précision les classes thématiques à extraire.
2. Analyser et évaluer l'existence de leur correspondance spectrale.
3. Sélectionner les zones d'échantillonnage (zones considérées représentatives des classes à déterminer).
4. Diviser en deux groupes les zones d'échantillonnage : un groupe pour l'établissement des signatures spectrales (zones d'entraînement), et un autre pour vérifier si la procédure produit bien les classes attendues (zones tests).
5. Établir les signatures spectrales.
6. Analyser les signatures spectrales. Sont-elles disjointes dans l'espace spectral ? Évaluer leur pouvoir discriminant.
7. Choisir l'algorithme de classification.
8. Effectuer une classification des zones d'entraînement. Établir et analyser la matrice de confusion. Cette première évaluation ne fait qu'orienter l'analyste sur les capacités de la procédure et les difficultés de discrimination entre classes.
9. Effectuer une classification sur les zones tests. Établir et analyser la matrice de confusion. Si les résultats ne sont pas satisfaisants, modifier

les zones d'entraînement, pour améliorer leur représentativité ou les classes thématiques, ou encore changer la procédure de classification. Cette étape est cruciale, car elle est à la base de l'évaluation de la qualité de l'image classée

10. Classifier l'ensemble de l'image

II.3 Les réseaux de neurones artificiels (RNA)

Un réseau neuronal est une méthode d'intelligence artificielle qui apprend à des ordinateurs à traiter les données d'une manière inspirée par le cerveau humain. C'est un type de processus d'apprentissage qui exploite des nœuds, ou neurones, interconnectés dans une structure à plusieurs couches similaire au cerveau humain, figure II.1). Les réseaux neuronaux artificiels tentent de résoudre des problèmes complexes tels que résumer des documents ou reconnaître des visages, avec davantage de précision, diagnostic d'images médical, identification des composés chimiques, contrôle des processus et de la qualité, cartographie automatique des images satellitaires [6].




Figure II. 1 Représentation du neurone biologique et du neurone formel

II. 3 .1 Les réseaux de neurones artificiels

II.3.1.1 Principe de base

L'unité de base du calcul dans un réseau de neurones artificiel est le neurone qui a été défini dans [16] en 1959. Un neurone artificiel reçoit des entrées de certains autres neurones ou d'une source externe ayant des valeurs numériques x_1, x_2, \dots, x_n auxquels il est connecté par des synapses et calcule une sortie y . Chaque entrée x_i a un poids associé w_i qui est attribué en fonction de son importance relative par rapport aux autres entrées. La valeur d'entrée x du neurone correspond à la somme pondérée de ses entrées en ajoutant une autre entrée ayant un poids b appelé biais. Ensuite, le neurone applique une fonction f sur cette somme, comme illustré à la figure II.2.




Figure II.2 Modélisation d'un neurone artificiel.

Où f est la fonction d'activation, qui sera détaillée ultérieurement. Le réseau de neurones à propagation avant -ou feedforward neural network- était le premier et le plus simple réseau de neurones artificiel mis au point. Il contient plusieurs neurones disposés en couches. Les neurones des couches adjacentes ont des connexions entre eux. Toutes ces connexions ont des poids qui leur sont associés, figure II.3. La sortie du neurone y , appelée activation de sortie, est calculée selon la formule suivante :

$$Y = f\left(\sum_{i=1}^n W_i X_i + B\right) \quad (\text{II.1})$$

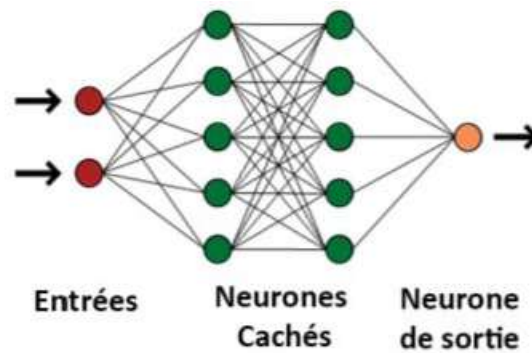


Figure II.3 Exemple d'un réseau de neurones artificiel.

Comme le montre la figure II.3 un réseau de neurones à propagation avant peut être constitué de trois types de neurones :

- **Neurones d'entrée** : les neurones d'entrée fournissent des informations du monde extérieur au réseau et construisent ensemble une « couche d'entrée ». Aucun calcul n'est effectué dans les nœuds d'entrée. Ils transmettent simplement les informations aux nœuds cachés.
- **Neurones cachés**: les neurones cachés n'ont pas de connexion directe avec le monde extérieur (d'où le nom "caché"). Ils effectuent des calculs et transfèrent des informations des neurones d'entrée aux neurones de sortie. Un ensemble de neurones cachés forme une « couche cachée ». Bien qu'un réseau à propagation avant n'avait historiquement qu'une seule couche d'entrée et une seule couche de sortie, il peut avoir aucune ou plusieurs couches cachées, selon un principe de généralisation.
- **Neurones de sortie**: les neurones de sortie construisent ensemble une « couche de sortie ». Ils sont responsables des calculs et du transfert des informations du réseau vers le monde extérieur.

Dans un réseau à propagation avant, les informations ne se déplacent que dans un seul sens, en partant des neurones d'entrée, passant par les neurones

cachées (s'ils existent) et en arrivant aux neurones de sortie. Un réseau de neurones peut être assimilé à un graphe orienté acyclique. Deux exemples de réseaux à propagation avant sont présentés dans la figure II.4 :

- perceptron mono-couche - Il s'agit d'un réseau de neurones à propagation avant le plus simple qui contient une couche cachée (Figure II.4.a).
- perceptron multi-couches - Il comporte une ou plusieurs couches cachées. Dans le cadre de ces travaux, nous ne traiterons que le cas des perceptrons multi-couches, car ils sont plus utiles que les perceptrons mono-couches dans les applications actuelles (Figure II.4.b)

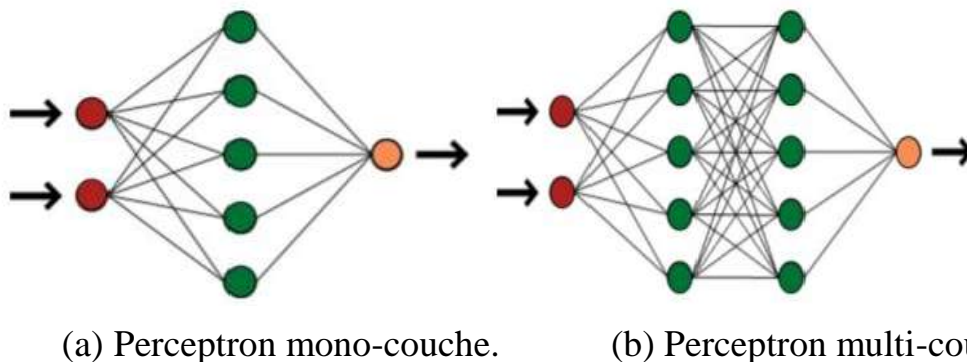


Figure II.4 Deux types de perceptrons

En se basant sur l'équation (II.1), un réseau de neurones peut être défini de la manière suivante. Soient :

r le nombre des neurones sur la couche d'entrée.

le vecteur de sortie $Y = (y_1, \dots, y_s)$ défini par la récurrence suivante :

l est le nombre total des couches du réseau de neurones.

n_k le nombre des neurones sur la $k^{\text{ème}}$ couche avec $0 \leq k \leq l$ tel que $n_0 = r$ et $n_l = s$

les fonctions affines $\sum_{j=1}^{n_{k-1}} W_{ij}^k X_j + b_i^k$ avec $1 \leq k \leq l$ $1 \leq i \leq n_k$, $x \in R^{n_{k-1}}$

f_a fonction d'activation du réseau de neurones.

le vecteur de sortie $Y = (y_1, \dots, y_s)$ défini par la récurrence suivante :

$\forall x \in$

$$R^r \left\{ \begin{array}{l} a_0 = x \\ a_i^k = f(A_i^k(a^{k-1})) \quad \text{avec } \forall 1 \leq k \leq j; 1 \leq i \leq n_k \\ y_i(x) = A_i^j(a^{j-1}) \quad \text{avec } \forall 1 \leq i \leq; \end{array} \right. \quad (\text{II.2})$$

II.3.2 Apprentissage d'un réseau de neurones

L'algorithme de rétro propagation est l'algorithme d'apprentissage le plus connu ; il a été créé par Rumelhart et Parker dans les années 80 généralisant la loi d'apprentissage de Widrow-Hoff à des réseaux de neurones multicouches constitués de fonctions de transfert continues différentiables [17]. C'est un algorithme de descente du gradient itératif permettant de minimiser la fonction d'erreur. Les vecteurs d'entrées et les vecteurs cibles correspondants sont utilisés pour apprendre le réseau. La fonction d'erreur E est donnée par l'équation suivante :

$$E = \frac{1}{2} \sum_{j=1}^N (D_j - O_j)^2 \quad (\text{II.3})$$

D_j et O_j représentent respectivement la sortie désirée et la sortie du neurone j dans la couche de sortie ; N représente le nombre de neurones dans la couche de sortie. Pour éviter les problèmes liés à une stabilisation dans un minimum local, on ajoute un terme 'inertie'. Celui-ci permet de sortir des minimums locaux dans la mesure du possible et de poursuivre la descente de la fonction d'erreur. À chaque itération, le changement de poids conserve les informations des changements précédents. Cet effet de mémoire permet d'éviter les oscillations et accélère l'optimisation du réseau. Le changement des poids avec inertie au temps t se traduit par:

$$\begin{cases} \Delta w_{ij} = -\frac{\partial E}{\partial w_{ij}} \\ \Delta w_{ij}(t+1) = \Delta_{ij} + w_{ij}(t) \end{cases} \quad (\text{II.4})$$

Dans cette équation, $w_{i,j}$ est la valeur de la connexion «poids» entre le

neurone i et le neurone j ; η est une constante positive appelée le taux d'apprentissage qui contrôle la quantité d'ajustement; α le momentum dont les valeurs sont comprises entre 0 et 1 est aussi appelé par le facteur de lissage ou de stabilisation et 't' est le nombre d'itération.

Algorithme du RNA

Data: base d'apprentissage \mathcal{A}

Résultat: poids du réseaux de neurone θ

initialisation aléatoire des poids du réseau (petites valeurs);

pour $e = 1$ à E **faire**

 mettre à jour μ_e ;

 mélanger la base d'apprentissage;

 diviser en sous-ensemble \mathcal{B}_k (mini-batches);

pour $k = 1$ à K **faire**

 mettre à jour les poids :

$$\theta^{(k+1)} = \theta^{(k)} - \frac{\mu_e}{|\mathcal{B}_k|} \sum_{n \in \mathcal{B}_k} \nabla_{\theta} J(f(x_n, \theta^{(k)}), y_n)$$

fin

fin

II.4 Machines à vecteur support

II.4.1 Définition

Les machines à vecteur support (ou SVM en anglais) se situent sur l'axe de développement de la recherche humaine des techniques d'apprentissage. Les SVMs sont une classe de techniques d'apprentissage introduite par Vladimir Vapnik au début des années 90 [17], elles reposent sur une théorie mathématique solide à l'inverse des méthodes de réseaux de neurones. Elles ont été développées au sens inverse du développement des réseaux de neurones: ces derniers ont suivi un chemin heuristique de l'application et l'expérimentation vers la théorie ; alors que les SVMs sont venues de la théorie du son vers l'application. Les SVMs sont dans leur origine utilisées pour la classification binaire et la régression.

Aujourd'hui, elles sont utilisées dans différents domaines de recherche et d'ingénierie tel que le diagnostic médical, le marketing, la biologie, la

reconnaissance de caractères manuscrits et de visages humains [17 ,18].

Cette technique est une méthode de classification à deux classes qui tente de séparer linéairement les exemples positifs des exemples négatifs dans l'ensemble des exemples. Chaque exemple doit être représenté par un vecteur de dimension. La méthode cherche alors l'hyperplan qui sépare les exemples positifs des exemples négatifs, en garantissant que la marge entre le plus proche des positifs et des négatifs soit maximale. Intuitivement, cela garantit un bon niveau de généralisation car de nouveaux exemples pourront ne pas être trop similaires à ceux utilisés pour trouver l'hyperplan mais être tout de même situés franchement d'un côté ou l'autre de la frontière. L'efficacité des SVM est très bonne pour la reconnaissance de formes. Un autre intérêt est la sélection de Vecteurs Supports qui représentent les vecteurs discriminant grâce auxquels est déterminé l'hyperplan. Les exemples utilisés lors de la recherche de l'hyperplan ne sont alors plus utiles et seuls ces vecteurs supports sont utilisés pour classer un nouveau cas. Cela en fait une méthode très rapide. Dans ce chapitre nous présentons les aspects théoriques de la méthode SVM [18].

II.4.2 Principe de la technique SVM

Le principe des SVM consiste à projeter les données de l'espace d'entrée (appartenant à deux classes différentes) non linéairement séparables dans un espace de plus grande dimension appelé espace de caractéristiques de façon à ce que les données deviennent linéairement séparables. Dans cet espace, on construit un hyperplan optimal séparant les classes tel que :

- Les vecteurs appartenant aux différentes classes se trouvent de différents côtés de l'hyperplan .
- La plus petite distance entre les vecteurs et l'hyperplan (la marge) soit maximale[19].

II.4.3 SVMs binaires

Le cas le plus simple est celui où les données d'entraînement viennent uniquement de deux classes différentes (+1 ou -1), on parle alors de classification binaire. L'idée des SVMs est de rechercher un hyperplan (droite dans le cas de deux dimensions) qui sépare le mieux ces deux classes Figure II.6

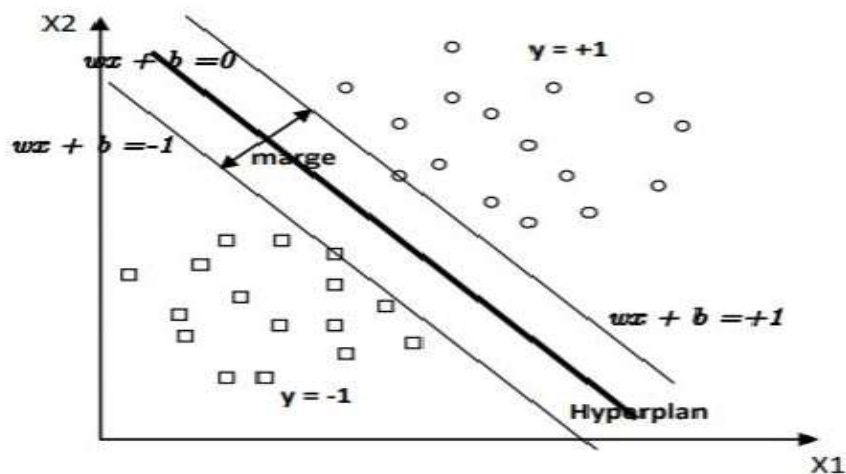


Figure II.6 SVM binaires

Si un tel hyperplan existe, c'est-à-dire si les données sont linéairement séparables, on parle

d'une machine à vecteur support à marge dure (Hard margin) [20].

II.4.4 SVM à marge dure

La machine à vecteurs de support (SVM) est l'une des approches les plus déterminantes de l'apprentissage supervisé utilisées pour la classification ou la régression. Ce modèle est

similaire à la régression logistique dans le sens où il est piloté par une fonction linéaire $W^T x + B.Cc$. Contrairement à la régression logistique, la machine à vecteurs de support ne fournit pas de probabilités, elle ne génère qu'une identité de classe. La classification se fait en séparant le jeu de données en deux

classes à travers une droite appelée hyperplan séparateur selon la formule suivant :

$$h(x) = \sum_{i=1}^n w_i a_i + B = w^T \cdot x + b \quad (\text{II.5})$$

Où $W = (w_1, w_2, \dots, w_n)$ le vecteur de poids, $x = (a_1, a_2, \dots, a_n)$ l'entrée à classer et b le biais.

Soit x_k un point à classer, selon le signe de $h(x_k)$, le SVM décide si x_k appartient à telle classe

$$\begin{cases} h(x_k) \geq 0 \rightarrow x_k \in \text{classe 1} \\ h(x_k) < 0 \rightarrow x_k \in \text{classe 2} \end{cases} \quad (\text{II.6})$$

Comme d'autres algorithmes d'apprentissage supervisé, une SVM nécessite l'apprentissage de données étiquetées pour la classification, soit l_k le label du point x_k ayant la valeur 1 si x_k appartient à la classe 1 et -1 s'il appartient à la classe 2. Dans le cas

où le SVM prédit correctement la bonne classe on aura $l_k (w^T \cdot x_k + b) \geq 0$. Donc, le but d'un SVM est de trouver le vecteur de poids w et le biais b vérifiant cette relation pour tout x_k et l_k . Cela conduit à trouver plus qu'un hyperplan séparant les deux classes. Pour résoudre ce problème, Vapnik et al. [19] ont montré que l'hyperplan optimal consiste à maximiser la marge entre les données et l'hyperplan séparateur. La marge est la distance minimale entre l'hyperplan et les échantillons les plus proches appelés vecteurs de supports (voir Figure). Cela revient à chercher les uniques w et b qui vérifient le problème (2.7)

$$\begin{cases} \text{minimiser} = \|w/2\|^2 \\ \text{sous les contraintes } \forall k, l_k \cdot x_k + b \geq 1 \end{cases} \quad (\text{II.7})$$

La résolution de ce genre de problème (II.7) se fait en utilisant la méthode des multiplicateurs de Lagrange [21] ce qui conduit à avoir les multiplicateurs de Lagrange optimaux α_k^* (le développement du calcul complet de cette méthode sort

du cadre de cette thèse). Après avoir remplacé le vecteur de poids w par sa valeur optimale $\sum_{k=1}^p x_k \alpha_k$, nous pouvons faire des prédictions à l'aide de la fonction :

$$H(x) = \sum_{k=1}^p \alpha_k^* l_k(x.x_k) + b \quad (\text{II.8})$$

Dans le cas non-linéaire où il n'existe pas d'hyperplan capable de séparer les données en deux classes, l'astuce du noyau -kernel trick- a été mise en place. L'idée est de considérer que si les données dans l'espace de départ E sont linéairement inséparables, alors il existe un autre espace E_0 de dimension supérieure dans lequel les données seraient linéairement séparables. La redistribution de ces données se fait à l'aide d'une fonction φ :

$E \rightarrow E$ non-linéaire. Cette astuce met en place la fonction noyau $K : E \times E \rightarrow \mathbb{R}$ défini par :

$K(x, x') = \varphi(x)^T \cdot \varphi(x')$. Dans ce cas, le calcul de l'hyperplan dans E ne nécessite la connaissance de K . La fonction noyau doit respecter les conditions du théorème de Mercer [22] qui impose que K soit continu, symétrique et semi-définie positive. Parmi les fonctions noyaux les plus utilisées, il y a le noyau polynomial, le noyau gaussien, le noyau Laplacien, etc. En utilisant la fonction K dans le cas non-linéaire, l'équation de l'hyperplan devient :

$$H(x) = \sum_{k=1}^p \alpha_k^* l_k k(x.x_k) + b \quad (\text{II.9})$$

L'astuce du noyau est puissante pour trois raisons. Premièrement, il nous permet d'apprendre des modèles non-linéaires dans un espace donné en les considérant comme des modèles linéaires dans un espace de dimension plus grande. Deuxièmement, le calcul se fait dans l'espace de départ qui est plus petit ce qui permet d'éviter des calculs coûteux. Troisièmement, la connaissance de la fonction φ n'est pas nécessaire puisqu'elle n'intervient pas dans les calculs. Les SVM ont été inventés par Vladimir N. Vapnik et Alexey Ya. Chervonenkis en 1963. Depuis cette date, les systèmes ont été utilisés pour la classification des textes et des

images. Ils peuvent travailler aussi avec des caractères manuscrits ainsi que la reconnaissance vocale [23]. Les algorithmes ont été utilisés pour résoudre le problème de suivi [24].

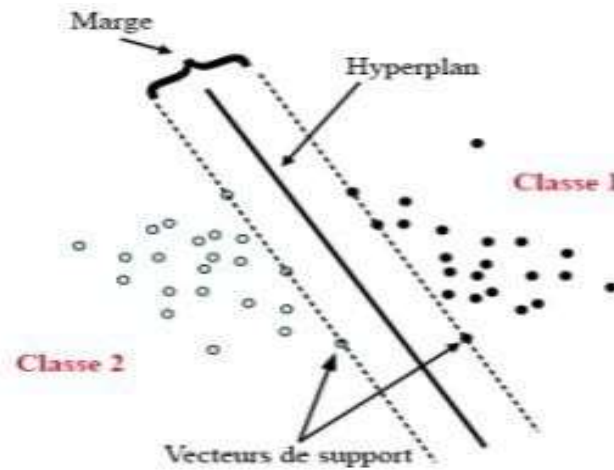


Figure II.7 Classification avec la machine à vecteurs de support.

Et dans les laboratoires de biologie pour effectuer des tâches telles que le tri des protéines. Le SVM a été utilisé aussi par Jun et al. Avec le RBM pour résoudre le problème de la détection du réseau trafic [25].

II.4.5 SVM à marge souple

En réalité, un hyperplan séparateur n'existe pas toujours, et même s'il existe, il ne représente pas généralement la meilleure solution pour la classification. En plus une erreur d'étiquetage dans les données d'entraînement (un exemple étiqueté +1 au lieu de -1 par exemple) affectera crucialement l'hyperplan.

Dans le cas où les données ne sont pas linéairement séparables, ou contiennent du bruit (outliers : données mal étiquetées) les contraintes de l'équation (II.5) ne peuvent être vérifiées, et il y a nécessité de les relaxer un peu. Ceci peut être fait en admettant une certaine erreur de classification des données (figure II.8) ce qui est appelé "SVM à marge souple (Soft Margin)" [26,27]. On introduit alors sur les contraintes des variables ξ_i dites de relaxation pour obtenir la contrainte de l'équation (II.10) :

$$l_k (w^T x_k + b) \geq 1 - \xi_{i,k=1 \dots n}, \quad (\text{II.10})$$




Figure II.8 SVM binaire à marge souple

Grâce aux variables de relaxation non négatives ξ , un hyperplan séparateur existera toujours. Si $\xi < 1$, ne respecte pas la marge mais reste bien classé, sinon x_k est mal classé par l'hyperplan. Dans ce cas, au lieu de rechercher uniquement un hyperplan séparateur qui maximise la marge, on recherche un hyperplan qui minimise aussi la somme des erreurs permises c-à-d minimisé

$$Q(w) = \sum_{k=1}^n \xi_k .$$

En combinant avec l'équation (II.7), on obtient le problème primal de l'équation (II.11) suivant [28]:

$$\begin{cases} \text{minimiser} & \frac{\|w\|^2}{2} + C \sum_{k=1}^n \xi_k \\ \text{sous les contrantrs } \forall^T & l_k(w^T \cdot x_k + b) \geq 1 - \xi_k \quad k = 1 \dots n \end{cases} \quad (\text{II.11})$$

Où C est un paramètre positif libre (mais fixe) qui représente une balance entre les deux termes de la fonction objective (la marge et les erreurs permises) c-à-d entre la maximisation de la marge et la minimisation de l'erreur de classification. On obtient le problème dual de l'équation (II.12) où on introduit les multiplicateurs de Lagrange α_k β_k :

$$(II.12) \quad Q(w,b, \alpha, \beta, \xi) = \frac{1}{2} W^T W C \sum_{k=1}^n \xi_k - \sum_{k=1}^n \alpha_k l_k(W^T x_k + b) = 1 + \xi_k - \sum_{k=1}^n \beta_k \xi_k$$

II.4.6 Architecture générale d'une machine à vecteur support

Une machine à vecteur support, recherche à l'aide d'une méthode d'optimisation, dans un ensemble d'exemples d'entraînement, des exemples, appelés vecteurs support, qui caractérisent la fonction de séparation. La machine calcule également des multiplicateurs associés à ces vecteurs. Les vecteurs supports et leurs multiplicateurs sont utilisés pour calculer la fonction de décision pour un nouvel exemple. Le schéma de la figure II.9 résume l'architecture générale d'une SVM dans le cas de la reconnaissance des chiffres manuscrits.

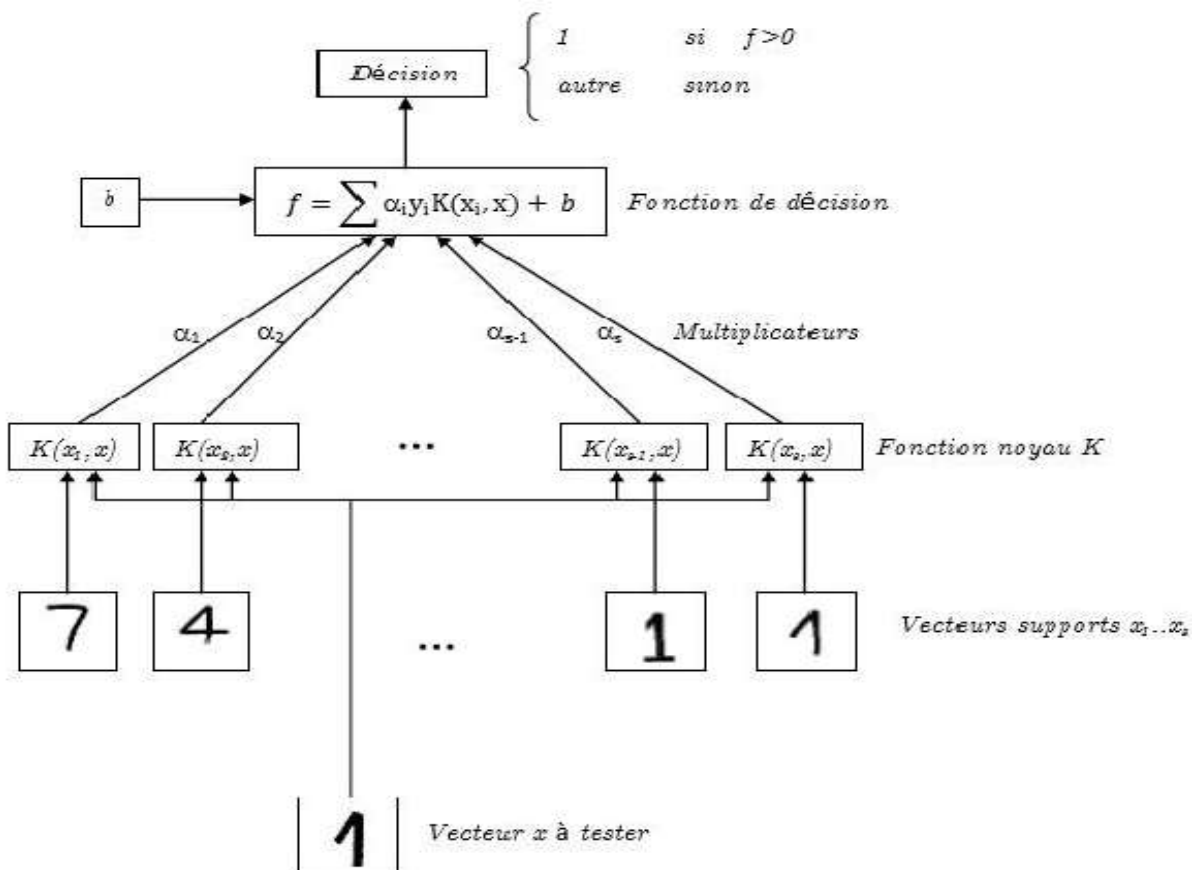


Figure II.9 Architecture d'une machine à vecteur support [29].

La fonction noyau K est utilisée pour calculer la distance entre le vecteur à tester x et chaque vecteur support dans l'espace de caractéristique. Les résultats sont

ensuite linéairement combinés en utilisant les multiplicateurs de L agrange et ajoutés au biais b . Le résultat final f permet de décider à propos du nouveau vecteur: si $f(x)$ est positive, il s'agit du chiffre "1", sinon, il s'agit d'un autre chiffre.

II.4.7 SVMs multi-classe

Les machines à vecteur support sont dans leur origine binaire. Cependant, les problèmes du monde réel sont dans la plupart des cas multi-classe, l'exemple le plus simple en est la reconnaissance des caractères optiques (OCR). Dans de tels cas, on ne cherche pas à affecter un nouvel exemple à l'une de deux classes mais à l'une parmi plusieurs, c-à-d que la décision n'est plus binaire et un seul hyperplan ne suffit plus. Les méthodes des machines à vecteur support multi-classe, réduisent le problème multi-classe à une composition de plusieurs hyperplans bi-classes permettant de tracer les frontières de décision entre les différentes classes [30]. Ces méthodes décomposent l'ensemble d'exemples en plusieurs sous-ensembles représentant chacun un problème de classification binaire. Pour chaque problème un hyperplan de séparation est déterminé par la méthode SVM binaire. On construit lors de la classification une hiérarchie des hyperplans binaires qui est parcourue de la racine jusqu'à une feuille pour décider de la classe d'un nouvel exemple. On trouve dans la littérature plusieurs méthodes de décomposition :

- **Une-contre-reste (1vsR)**

C'est la méthode la plus simple et la plus ancienne. Selon la formulation de Vapnik[31], elle consiste à déterminer pour chaque classe k un hyperplan $H_k(W_k, b_k)$ la séparant de toutes les autres classes. Cette classe k est considéré comme étant la classe positive (+1) et les autres classes comme étant la classe négative (-1), ce qui résulte, pour un problème K classes, en K SVM binaires. Un hyperplan H_k est défini pour chaque classe k par la fonction de décision suivante :

$$H_k(x) = \text{signe} (\langle w_k, x \rangle + b_k) =$$

$$\begin{cases} +1 & \text{si } f_k(x) > 0 \\ 0 & \text{sinon} \end{cases}, \quad (\text{II.13})$$

La valeur retournée de l'hyperplan permet de savoir si x appartient à la classe k ou non. Dans le cas où il n'appartient pas à K ($H_k = 0$), nous n'avons aucune information sur

l'appartenance de x aux autres classes. Pour le savoir, on présente x à tous les hyperplans,

ce qui donne la fonction de décision de l'équation (II.14) suivante :

$$k^* = \arg \max (H_k(x)), (1 \leq k \leq K) \quad (\text{II.14})$$

Si une seule valeur $H_k(x)$ est égale à 1 et toutes les autres sont égales à 0, on conclut que x appartient à la classe k . Le problème est que l'équation (II.14) peut être vérifiée pour plus d'une classe, ce qui produit des régions d'ambiguïté, et l'exemple x est dit non classifiable. La figure représente un cas de séparation de 3 classes Figure II.2.6 .




Figure II.10 Approche une-contre-reste avec des zones d'indécision

- **Une-contre-une (1vs1)**

Cette méthode, appelée aussi "pairwise", revient à Kner et ses co-auteurs [32] qui l'ont proposée pour les réseaux de neurones. Elle consiste à utiliser un classifieur pour chaque paire de classes. Au lieu d'apprendre K fonctions de décisions, la

méthode 1vs1 discrimine chaque classe de chaque autre classe, ainsi $K(K - 1)/2$ fonctions de décisions sont apprises.

Pour chaque paire de classes (k, s) , la méthode 1vs1 définit une fonction de décision binaire $h_{ks}: \mathbb{R} \rightarrow \{-1, +1\}$. L'affectation d'un nouvel exemple se fait par liste de vote. On teste un exemple par le calcul de sa fonction de décision pour chaque hyperplan. Pour chaque test, on vote pour la classe à laquelle appartient l'exemple (classe gagnante). On définit pour le faire la fonction de décision binaire (x) de l'équation .

$$H_{ks}(x) = \text{signe}(f_{ks}(x)) = \begin{cases} +1 & \text{si } f_{ks}(x) > 0 \\ 0 & \text{sinon} \end{cases}, \quad (\text{II.15})$$

Sur la base de $\frac{K(K-1)}{2}$ fonctions de décision binaires, on définit K autres fonctions de décision (équation) :

$$H_k(x) = \sum_{s=1}^m H_{ks}(x) \quad (\text{II.16})$$

La (Figure) représente un exemple de classification de trois classes avec la zone d'indécision.




Figure II.11 Approche une-contre-une

Bien que La méthode 1vs1 utilise, pour l'entraînement, un nombre plus important d'hyperplans que la méthode 1vsR, elle est souvent plus rapide. Cela est du, d'une part, au nombre limité d'exemples utilisés pour entraîner chaque hyperplan, et

d'autre part, à la simplicité des problèmes à résoudre. En effet, chaque deux classes prises à part sont moins chevauchées que toutes les classes.

II.4.8 Étapes de l'algorithme SVM pour la classification: cas 1 contre le reste

1. Prétraitement des données :

- Normalisation des données : Les données sont souvent normalisées pour s'assurer que chaque variable a une échelle comparable.
- Transformation des caractéristiques : Parfois, les caractéristiques sont transformées en utilisant des techniques comme l'analyse en composantes principales (PCA) pour réduire la dimensionnalité ou améliorer la séparabilité des classes.

2. Construction de l'hyperplan de décision :

- L'objectif de SVM est de trouver l'hyperplan qui maximise la marge entre les exemples de différentes classes.
- Pour les données linéairement séparables, un hyperplan linéaire est utilisé pour séparer les classes. La forme générale de l'hyperplan est déterminée par une fonction de décision qui est une combinaison linéaire des caractéristiques.

3. Optimisation de la marge :

- SVM cherche à maximiser la marge, qui est la distance entre l'hyperplan de décision et les points de données les plus proches de chaque classe, appelés vecteurs de support.
- Les vecteurs de support sont les points critiques qui influencent l'hyperplan et la séparation des classes.

4. Utilisation de la fonction de perte et des contraintes :

- Pour les données non linéairement séparables, SVM utilise des fonctions de perte et des contraintes pour minimiser les erreurs de classification et ajuster l'hyperplan tout en maximisant la marge.

- Les techniques de pénalisation (soft-margin SVM) sont utilisées pour traiter les erreurs de classification et ajuster l'hyperplan de manière plus flexible.

5. Classification des nouveaux exemples :

- Une fois l'hyperplan de décision optimisé trouvé, il est utilisé pour prédire la classe de nouveaux exemples en évaluant de quel côté de l'hyperplan ils se trouvent.

II.5 Méthode K plu proches voisins

L'apprentissage automatique des K-plus proches voisins (KPPV) est une méthode fréquemment employée pour classer les données. Dernièrement, cette méthode a été réemployée pour des fins de diagnostic, c'est-à-dire la détection et l'isolation. D'abord présenté en 1951 par Evelyn Fix et Joseph Hodges, l'algorithme a été utilisé pour classer les plantes en fonction de leurs caractéristiques mesurée [33].

Le fonctionnement de la méthode KPPV repose sur le calcul de la distance entre un point de données d'entrée et tous les autres points de données dans l'ensemble de données d'apprentissage. Par la suite, on identifie les k points de données les plus proches, et on utilise la classe ou la valeur de ces k points de données pour prédire la classe ou la valeur du point de données d'entrée. La détection et l'isolation des défauts dans les données peuvent être extrêmement bénéfiques, car les points de données aberrants qui diffèrent des autres points de données dans l'ensemble des données d'apprentissage peuvent être identifiés comme des données défectueuses.

L'apprentissage automatique des K-plus proches voisins (KPPV) est une méthode fréquemment employée pour classer les données. Dernièrement, cette méthode a été réemployée pour des fins de diagnostic, c'est-à-dire la détection et l'isolation.

II.5.1 Principe de la méthode KPPV

L'algorithme des k plus proches voisins, également connu sous le nom de KNN ou KPPV, est un classificateur d'apprentissage supervisé non paramétrique, qui utilise

la proximité pour effectuer des classifications ou des prédictions sur le regroupement d'un point de données individuel. Il est généralement utilisé comme algorithme de classification en partant de l'hypothèse que des points similaires peuvent être trouvés les uns à côtés des autres. Cependant, avant qu'une classification puisse être faite, la distance doit être définie. La distance euclidienne est la plus couramment utilisée, que nous aborderons plus en détail ci-dessous.

Il convient également de noter que l'algorithme KNN fait également partie d'une famille de modèles "d'apprentissage paresseux", ce qui signifie qu'il ne stocke qu'un ensemble de données d'entraînement au lieu de subir une étape d'entraînement. Cela signifie également que tous les calculs ont lieu lorsqu'une classification ou une prédiction est effectuée. Puisqu'il s'appuie fortement sur la mémoire pour stocker toutes ses données d'entraînement, il est également appelé méthode d'apprentissage basée sur les instances ou basée sur la mémoire. [13]

II.5.2 Algorithme de KPPV pour la classification

En intelligence artificielle, plus précisément en apprentissage automatique, la méthode des k plus proches voisins est une méthode d'apprentissage supervisé. En abrégé KPPV ou k-PPV en français, ou plus fréquemment k-NN ou KNN, de l'anglais k-nearest neighbors. C'est un algorithme d'apprentissage automatique qui peut être employé pour la classification, la régression et le regroupement. Le fonctionnement de l'algorithme consiste à repérer les k-voisins les plus proches d'un point de donnée. Ensuite, on peut classer ou prédire l'étiquette de ce point de données en fonction des étiquettes de ses voisins. Il est possible d'ajuster la valeur de k afin d'améliorer les performances de l'algorithme. Le but de l'algorithme KNN est de réaliser la tâche de manière efficace en choisissant la valeur optimale du k à partir des résultats obtenus.

● Les étapes de l'algorithme

1. Tout d'abord, l'algorithme prend en entrée un nouvel échantillon de données de test pour lequel la classe doit être prédite.

2. Ensuite, l'algorithme calcul la distance entre cet exemple et tous les exemples de la base de données d'entraînement, généralement en utilisant une mesure de distance telle que la distance euclidienne.
3. L'algorithme sélectionne les K exemples les plus proches du nouvel exemple en termes de distance. Ces exemples sont appelés les K plus proches voisins.
4. Pour la classification, l'algorithme attribue la classe majoritaire parmi les K plus proches voisins au nouvel exemple. Pour la régression, l'algorithme prédit la moyenne des valeurs des K plus proches voisins.
5. Enfin, l'algorithme renvoie la classe prédite ou la valeur prédite pour le nouvel exemple.

Avant d'exécuter l'algorithme, il est essentiel de spécifier la valeur de K, un paramètre essentiel de l'algorithme. La décision sera influencée par les bruits dans les données si K est trop faible, tandis que si K est trop élevé, la décision sera trop générale et ne pourra pas identifier les subtilités des données.

Les applications de l'algorithme KNN comprennent la classification d'images, la reconnaissance de caractères manuscrits, la prédiction des prix de l'immobilier, et bien d'autres encore.




Figure II.12 Fonctionnement de l'algorithme k-NN

Pour identifier les points de données les plus proches d'un point de requête spécifique, il sera nécessaire de calculer la distance entre le point de requête et les

autres points de données. Ces mesures de distance contribuent à créer des frontières de décision, qui répartissent les points de demande en diverses zones.

● Distance dans un algorithme KPPV

Distance euclidienne (p=2) : il s'agit de la mesure de distance la plus couramment utilisée, et elle est limitée aux vecteurs à valeurs réelles. En utilisant la formule cidessous, il mesure une ligne droite entre le point de requête et l'autre point mesuré.

$$(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (\text{II.17})$$

Distance de Manhattan (p=1) : il s'agit également d'une autre mesure de distance populaire, qui mesure la valeur absolue entre deux points. Elle est également appelée distance en taxi ou distance d'un pâté de maisons, car elle est généralement visualisée avec une grille, illustrant comment on peut naviguer d'une adresse à une autre via les rues de la ville .

$$d_H = \sum_{i=1}^m |x_i - y_i| \quad (\text{II.18})$$

Hemming distance : Cette technique est généralement utilisée avec des vecteurs booléens ou de chaîne, identifiant les points où les vecteurs ne correspondent pas. En conséquence, il a également été appelé la métrique de chevauchement. Ceci peut être représenté par la formule suivante :

$$d_H = \sum_{i=1}^m |x_i - y_i| \quad (\text{II.19})$$

$$x = y \quad d_H = 0$$

$$x \neq y \quad d_H \neq 0$$

Avantage

- L'algorithme est simple et facile à mettre en œuvre.

- Il n'est pas nécessaire de construire un modèle, d'ajuster plusieurs paramètres ou de faire des hypothèses supplémentaires.
- L'algorithme est polyvalent. Il peut être utilisé pour la classification, la régression et la recherche d'informations (comme nous le verrons dans la section suivante) [14].

Désavantage

- Intensif en calcul : KNN peut être intensif en calcul, en particulier lorsque vous travaillez avec de grands ensembles de données d'apprentissage. L'algorithme doit calculer la distance entre le nouveau point de données et tous les points de données d'apprentissage, ce qui peut prendre du temps.
- Sensible au choix de K : La performance de KNN est sensible au choix du nombre de plus proches voisins (K). Si K est trop petit, le modèle peut être sensible aux données bruitées, tandis que si K est trop grand, le modèle peut être trop général et ne pas capturer la structure sous-jacente des données.
- Ne convient pas aux données de grande dimension : KNN ne convient pas aux données de grande dimension car la distance entre les points de données devient moins significative dans les espaces de grande dimension. C'est ce qu'on appelle la "malédiction de la dimensionnalité".
- Nécessite un grand espace mémoire : KNN doit stocker l'intégralité de l'ensemble d'apprentissage en mémoire, ce qui peut poser problème lorsque vous travaillez avec de grands ensembles de données.

II.6 Conclusion

Nous avons présenté dans ce chapitre les principales méthodes de segmentation issues de la classification automatique les plus populaires en intelligence artificielle ainsi que leurs caractéristiques, leurs avantages et leurs algorithmes. Nous nous

somme intéressé seulement aux trois méthodes présentées vu leurs intérêt pratique pour les images de télédétection.

La mise en œuvre de ces méthodes va faire l'objet du chapitre

CHAPITRE III
Résultats et
Interprétations

III.1 Introduction

La classification est un processus de reconnaissance des formes. En télédétection, elle consiste à effectuer la correspondance entre une scène de l'image matérialisée généralement par leurs valeurs radiométriques et des classes connues a priori ou non par l'utilisateur. Pour atteindre ces objectifs, les images satellitaires sont utilisées pour obtenir une vue d'ensemble et une couverture spatiale étendue, ce qui permet une analyse à grande échelle et à long terme des caractéristiques aquatiques de la Terre. Dans ce chapitre nous avons proposé trois méthodes de classification supervisée RNA, SVM et KNN pour détecter les zones d'eau (mer interne, oued, marécage) à partir de l'image satellitaire.

III.2 Objectifs de la détection d'eau à partir d'images satellitaires

L'objectif de la détection d'eau à partir d'images satellitaires est généralement de cartographier et de surveiller les étendues d'eau à l'échelle régionale ou mondiale.

Voici quelques-uns des principaux objectifs et intérêts associés [34]:

- **Surveillance des ressources en eau** : Identifier les zones d'eau douce disponibles, telles que les lacs, les rivières et les réservoirs, pour évaluer les ressources en eau disponibles.
- **Gestion des ressources en eau** : Faciliter la gestion durable des ressources en eau en suivant les changements dans la couverture et l'utilisation des terres à proximité des cours d'eau et des plans d'eau.
- **Détection des inondations** : Détecter et suivre les zones inondées après des événements météorologiques extrêmes, ce qui est crucial pour les opérations de secours et la planification d'urgence.
- **Étude du changement climatique** : Observer les changements à long terme dans les étendues d'eau, comme la fonte des glaciers et la dynamique des calottes glaciaires, en relation avec le changement climatique.
- **Suivi de l'impact humain** : Identifier les changements causés par l'activité humaine, tels que la construction de barrages, l'urbanisation autour des cours d'eau et les changements dans l'utilisation des terres agricoles.

- **Analyse environnementale** : Évaluer la qualité de l'eau et l'état écologique des habitats aquatiques en surveillant les étendues d'eau et en identifiant les sources potentielles de pollution.

III.3 Image satellitaire

Une image satellitaire est une image numérique. La particularité de cette image est qu'elle est prise par un satellite placé en orbite autour de la planète. Elle est aussi synthétique, flexible, précise et actuelle (renouvellement de l'information automatique ou à la demande).

III.3.1 Définitions

Une image satellitaire est une représentation graphique, constituée de nombreux carrés appelés pixels, figure III.1. Le pixel représente la plus petite unité figurant sur une image satellitaire, quelle que soit la longueur d'onde ou le dispositif de télédétection qui ont été utilisés pour capter et enregistrer l'énergie électromagnétique.

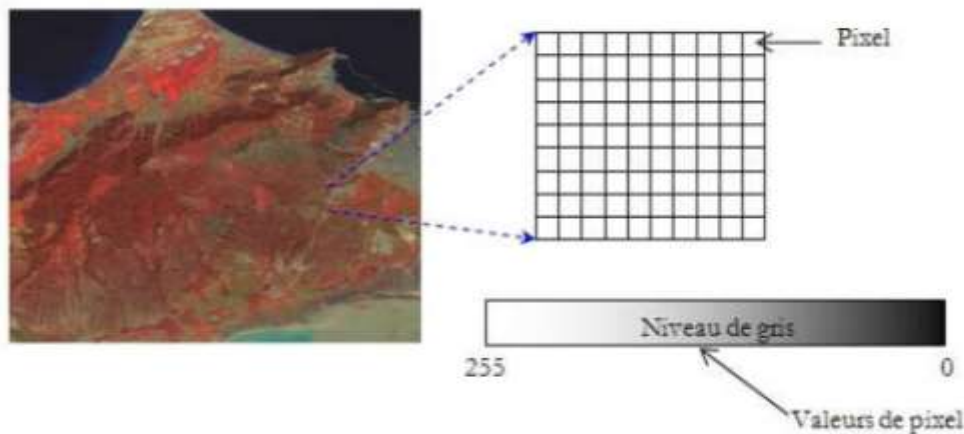


Figure III.1 Image satellitaire « Oran » (LANDSAT 5 -TM)

Cette énergie électromagnétique est généralement captée par un capteur qui est un dispositif électronique permettant de recueillir ou de transformer l'énergie. En télédétection, il existe deux types de capteurs, figure III.2 :

Capteurs passifs : Ils sont en général les capteurs qui utilisent une source d'énergie externe pour observer les objets.

Capteurs actifs : On les appelle capteurs actifs car ils émettent eux-mêmes les rayonnements pour « illuminer » les objets de manière à ce que l'énergie réfléchie puisse être mesurée.




Figure III.2 Capteur actif et passif

Afin d'obtenir des informations différentes, les capteurs observent la terre dans plusieurs bandes de longueurs d'onde, encore appelées "canaux". On dit qu'ils sont multi spectraux. A chaque pixel sont associées plusieurs valeurs radiométriques comprises entre 0 et 255. Mathématiquement c'est une fonction $F(x, y)$ à deux variables entières x et y qui sont respectivement la ligne et la colonne, fournissant une ou plusieurs valeurs entières représentant le niveau de gris du pixel dans les différents canaux.

III.2.2. Propriétés de l'image satellitaire

- **Resolution Spatial**

Le premier fait important à connaître concernant une image satellite est sa résolution spatiale d'une image est la plus petite distance entre puisse identifier.



Figure III.3 Démonstration de la résolution spatiale

- **Résolution spectrale**

Elle décrit la capacité d'un capteur à utiliser de petites fenêtres de longueurs d'onde. Plus la résolution spectrale est fine, plus les fenêtres des différents canaux du capteur sont étroites. Par cette résolution, on peut distinguer plusieurs types d'images satellitaires

III.4 prétraitements

L'étape de prétraitement a pour but de faciliter la segmentation en renforçant la ressemblance entre pixels appartenant à une même région, ou en accentuant la dissemblance entre pixels appartenant à des régions différentes.

- **Modification d'histogramme**

Le but de cette étape est d'améliorer l'image, pour cela on applique une transformation ponctuelle d'intensité. A tout pixel d'intensité as on associe une intensité $a=T(as)$. Du fait de leur caractère ponctuel, les méthodes de transformation d'histogramme n'affectent pas la forme des régions. Elles en modifient uniquement l'apparence visuelle.

- **Réduction de bruit**

Le bruit constitue des perturbations qui affectent la qualité de la segmentation et sont généralement désignées sous le terme de bruit d'image. Ce traitement a pour

but de réduire l'amplitude des variations d'intensité dans chaque région, tout en conservant les transitions entre régions adjacentes.

- **Rehaussement de contraste**

Il arrive toutefois que la transition entre régions (constituant l'image) soit initialement floue, c'est-à-dire, quelle s'étale sur plusieurs pixels. Rehausser le contraste de l'image consiste à diminuer l'étendue de la zone de transition sans affecter l'intensité moyenne des régions situées de part et d'autre. limite le risque de fusion intempestive de régions distinctes lors de la phase de segmentation.

- **Seuillage d'un histogramme monodimensionnel**

A partir de l'histogramme d'un seul canal, cette technique consiste à ne retenir que les pixels dont la radiométrie est comprise entre deux valeurs. Elle permet cependant dans certains cas de séparer certains thèmes bien caractéristiques, ces thèmes se traduisant souvent sur l'histogramme par la présence de plusieurs « bosses »

III.5 Avantage des traitements en télédétection

Les avantages des traitements numériques se situent aux niveaux suivants :

- Meilleure visualisation
- Souplesse d'édition
- Facilités de cartographie
- Estimation de surface
- Réduction de dimensions

III.6 Base de Données

Nous avons utilisé la base de données 'C Merced Land Use Dataset' , Il s'agit d'un ensemble de données d'images d'utilisation des terres de 21 classes destiné à des fins de recherche. Il y a 100 images pour chacune des classes suivantes : agricole, avion,

baseball, diamant, plage, forêt, rivière, réservoirs de stockage ect. Chaque image mesure 256x256 pixels. Les images ont été extraites manuellement à partir de grandes images de la collection d'images de zones urbaines de la carte nationale de l'USGS.

III.7 Evaluation de la précision

Il existe de nombreuses façons (les fameuses métriques) d'évaluer les performances de classification, mais aucune n'a résisté à l'épreuve du temps comme la matrice de confusion. Elle nous aide à évaluer les performances de notre modèle, à déterminer où il a mal fonctionné et nous offre des conseils pour corriger notre modèle ou ses hyper paramètres.

III.7.1 Qu'est-ce qu'une matrice de confusion

Une matrice de confusion est une matrice $N \times N$ utilisée pour évaluer la performance d'un modèle de classification, où N est le nombre de classes cibles. La matrice compare les valeurs cibles réelles avec celles prédites par le modèle d'apprentissage machine.. Cela nous donne une vue d'ensemble des performances de notre modèle de classification et des types d'erreurs qu'il commet. De la matrice de confusion (dans le cas de deux classes 1 et 0) on note :

- Vrai positif (TP comme true positive) la valeur prévue correspond à la valeur réelle la valeur réelle est 1 (ou positive) et le modèle prévoit une valeur de 1 (ou positive)
- Vrai négatif (TN comme true négatif) la valeur prévue correspond à la valeur réelle la valeur réelle est 0 (ou négative) et le modèle prévoit une valeur de 0 (ou négatif)
- Faux positif (FP comme fautive positive) – fautive alarme la valeur prédite est fautive la valeur réelle est 0 (ou négative) mais le modèle prédit une valeur 1 (ou positive) également connu sous le nom d'erreur de type 1

- Faux négative (FN comme false négative) la valeur prédite est fausse la valeur réelle est 1 (ou négative), mais le modelé prédit une valeur 0 (ou négative) également connue sous le nom d'erreur de type 2

Les différentes valeurs de la matrice de confusion seraient les suivantes :

- Vrai positif (TP) = 100 ; ce qui signifie que 100 points de données de classe positive ont été correctement classes par le modelé
- Vrai négatif (TN) = 50 ; ce qui signifie que 50 points de données de classe négative ont été correctement classes par le modelé
- Faux positive (FP)= 10 ; ce que signifie que 10 points de données de la classe négative ont été incorrectement classes comme appartenant a la classe positive par les module
- Faux négative (FN) = 5 ; ce qui signifie que 5 points de données de classe positive ont été incorrectement classes comme appartenant à la classe négative par les module

III .7.2 Définition des métriques

● Précision et rappel

La précision nous indique combien de cas correctement prévus se sont avérés positifs voici comment calculer la précision :

$$\text{Précision} = \frac{TP}{TP+FP} \quad (\text{III.1})$$

Cela permet de démontrer si notre modelé est fiable ou non . Le rappel nous indique combien de cas positifs réels nous avons pu prévoir correctement avec notre modelé et voici comment nous pouvons calculer le rappel :

$$\text{Rappel} : \frac{TP}{TP+FN} \quad (\text{III.2})$$

● F-mesure ou F-score

En pratique , lorsque nous essayons d'augmenter la précision de notre modelé ,le rappel diminuer , vice-versa la F-mesure saisit les deux tendances en une seule valeur :

$$FMesure = \frac{2}{\frac{1}{Précision} + \frac{1}{rappel}} \quad (III.3)$$

Le F-mesure est une moyenne harmonique de la précision et du rappel , et elle donne donc une idee combinée de ces deux mesures elle est maximale lorsque la précision est égale au rappel .

III.8 Résultats et interprétations

Dans notre travail les données sont des images en RBV de dimension 256x256 pixels ils ont subit une transformation de matrice vers une ligne de dimension 65536 ce qui constitue une série de donnée de dimension 3 ligne de 65536 valeurs correspondant aux trois images RVB en niveau de gris. Ces données ont été ensuite normalisé pour avoir des valeurs au dessus de 1. La sortie de ce système d'apprentissage est constituée d'une donnée soit 1 ou 0.

III.8.1 Les réseaux de neurones artificiels (RNA)

Le réseu de neurones choisis est à rétropropagation d'une suele couche cachée de 10 neurones, ce chois a été fixé après plusieurs test, voir la figure III.4.




Figure III.4 Structure du réseau de neurones artificiels utilisé

III.8.1.1 Résultats de la segmentation par RNA

L'application de cette méthode sur trois image de la base de données nous a donné les résultats ci-dessous.


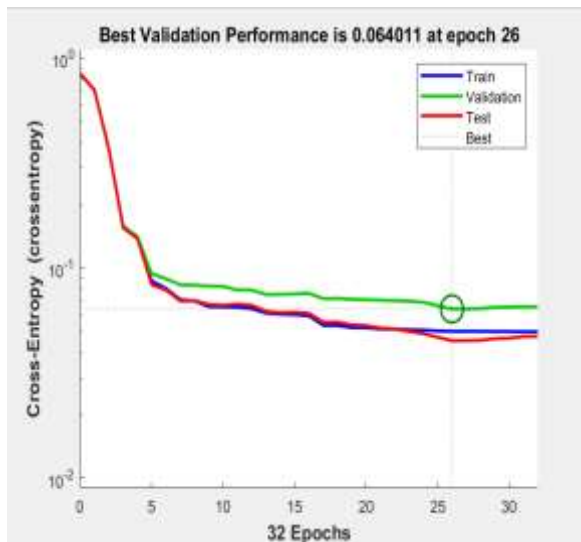
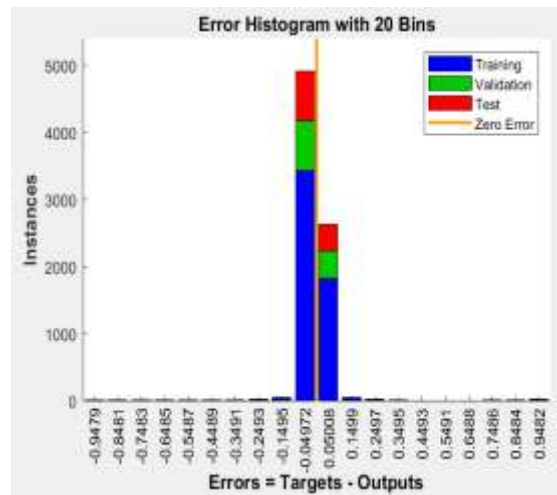


Figure III.5 Résultat de la segmentation par RNN (image 182)

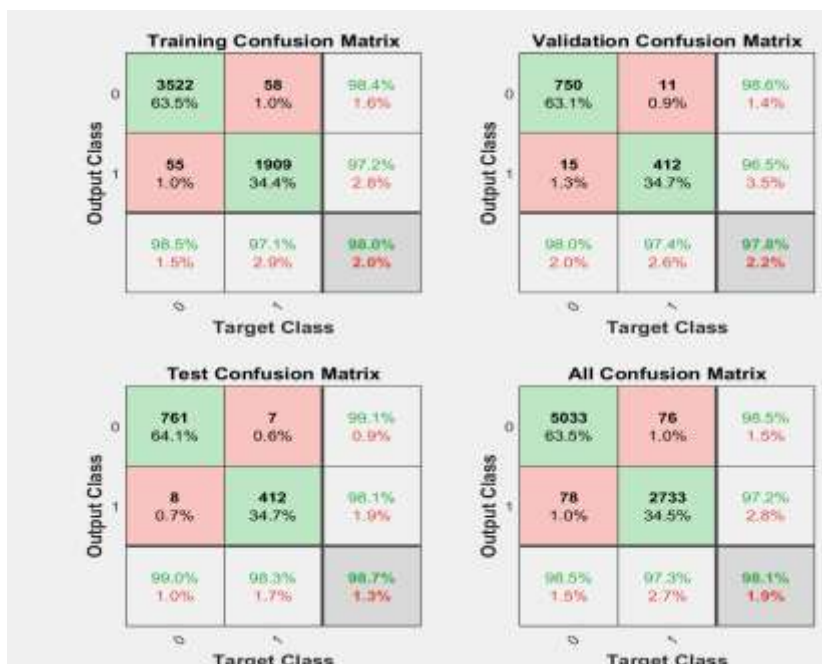
(a) Image originale ; (b) Image référence ; (c) Image obtenue par RNN



(a) Performance de la segmentation



(b) Erreur d'historgramme de la segmentation



(c) Matrice de confusions

Figure III. 6 Performance de la classification (image 182)






Figure III.3 Résultat de la segmentation par RNA (image 103)
 (a) Image originale ; (b) Image référence; (c) Image obtenue par RNA



(a) Performance de la segmentation

(b) Erreur d'histomage de la segmentation



(c) Matrice de confusion

Figure III.7 Performance de la segmentation


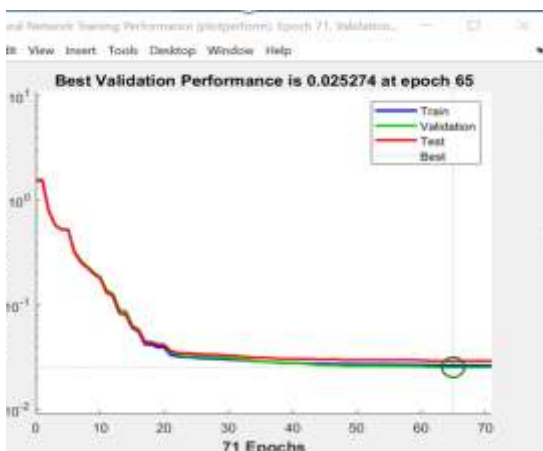
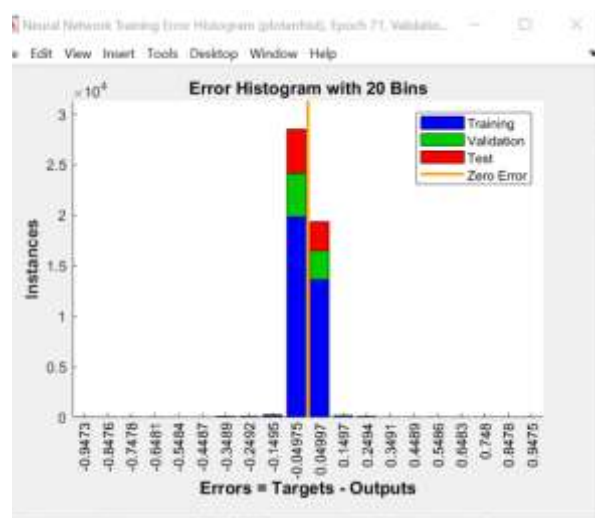


Figure III.8 Résultat de la segmentation par RNA (image 102)

(a) Image originale ; (b) Image référence ; (c) Image obtenue par RNA



(a)Performance de la segmentation



b)Erreur d'histogramme de la segmentation



(c)Matrice de confusion

Figure III.9 Performance de la segmentation

III.8.1.2 Evaluation de la précision de la méthode RNA

On remarque que pour cette méthode la précision est de 0.98 et Fmesure est aussi de 0.98, cette dernière prouve que la méthode RNA est précise et très robuste, tableau III.1.

Tableau III.1 Métriques de la méthode RNA

	TP	TN	FP	FN	Précision	Rappel	Fmesure
IMAGE 182	22309	26518	253	240	0.98	0.98	0.98
IMAGE 103	342771	400346	5236	2467	0.98	0.99	0.97
IMAGE 102	22305	26518	253	240	0.98	0.98	0.98

III.8.2 Les machines à support vecteurs (SVM)

III.8.2.1 Résultats de la segmentation pa SVM

L'application de cette méthode sur trois image de la base de données nous a donné les résultats ci-dessous.

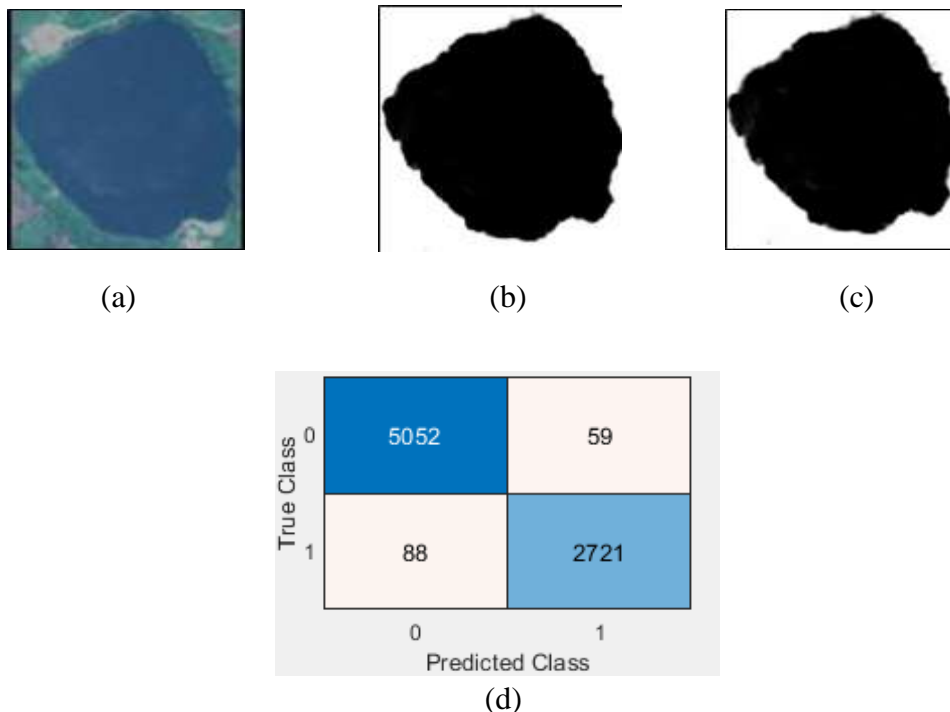


Figure III.10 Résultat de la segmentation par SVM (image 182)

- (a) Image originae ; (b) Image Image référence ; (c) Image obtenue par SVM,
- (d) matrice de confusion

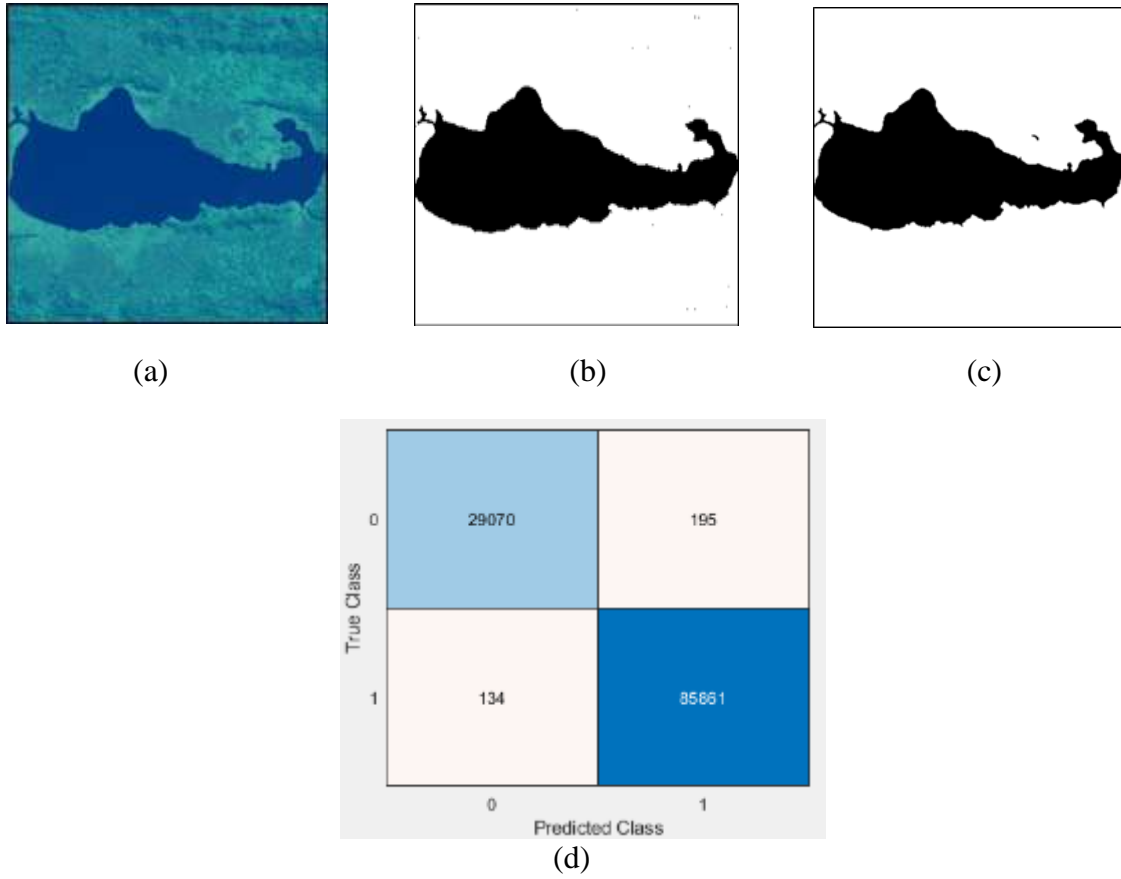


Figure III.11 Résultat de la segmentation par SVM (image 103)

(a) Image originale ; (b) Image référence ; (c) Image obtenue par SVM,
 (d) matrice de confusion

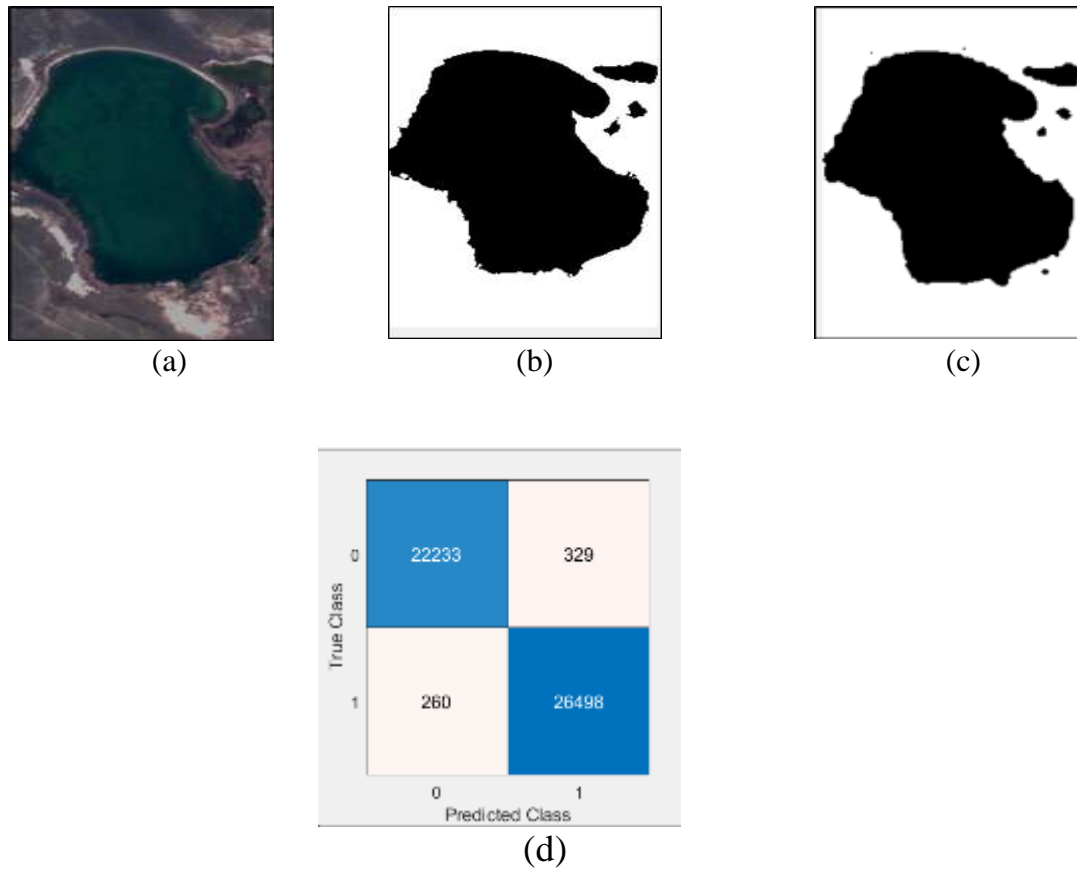


Figure III.12 Résultat de la segmentation par SVM (image 102)

(a) Image originale ; (b) Image référence ; (c) Image obtenue par SVM, (d) matrice de confusion

III.8.2.2 Evaluation de la précision de la méthode SVM

On remarque que pour cette méthode la précision est de 0.99 et Fmesure est aussi de 0.84, cette dernière prouve que la méthode SVM est précise mais elle présente un rappel maximal de 0.74. La précision et le rappel nous donne une Fmesure de 0.84? Tableau III.2.

Tableau III.2 Métriques de la méthode SVM

	TP	TN	FP	FN	Précision	Rappel	Fmesure
IMAGE 182	26498	260	329	22233	0.98	0.5	0.6
IMAGE 102	2721	88	59	5052	0.97	0.35	0.51
IMAGE 103	85861	134	195	29070	0.99	0.74	0.84

III.8.3 La méthode des K plus proche voisin (KPPV)

III.8.3.1 Résultats de la segmentation pa KPPV

L'application de cette méthode sur trois image de la base de données nous a donné les résultats ci-dessous.

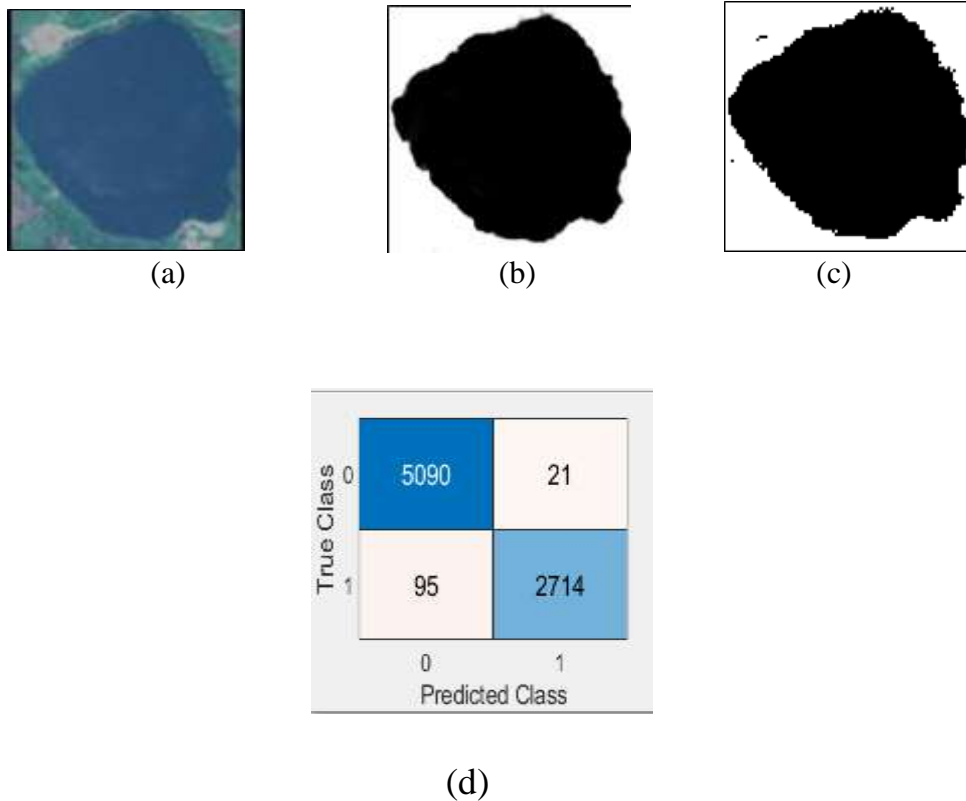


Figure III.13 Résultat de la segmentation par KPPV (image 182)

(a) Image originae ; (b) Image référence ; (c) Image obtenue par KPPV,
(d) matrice de confusion

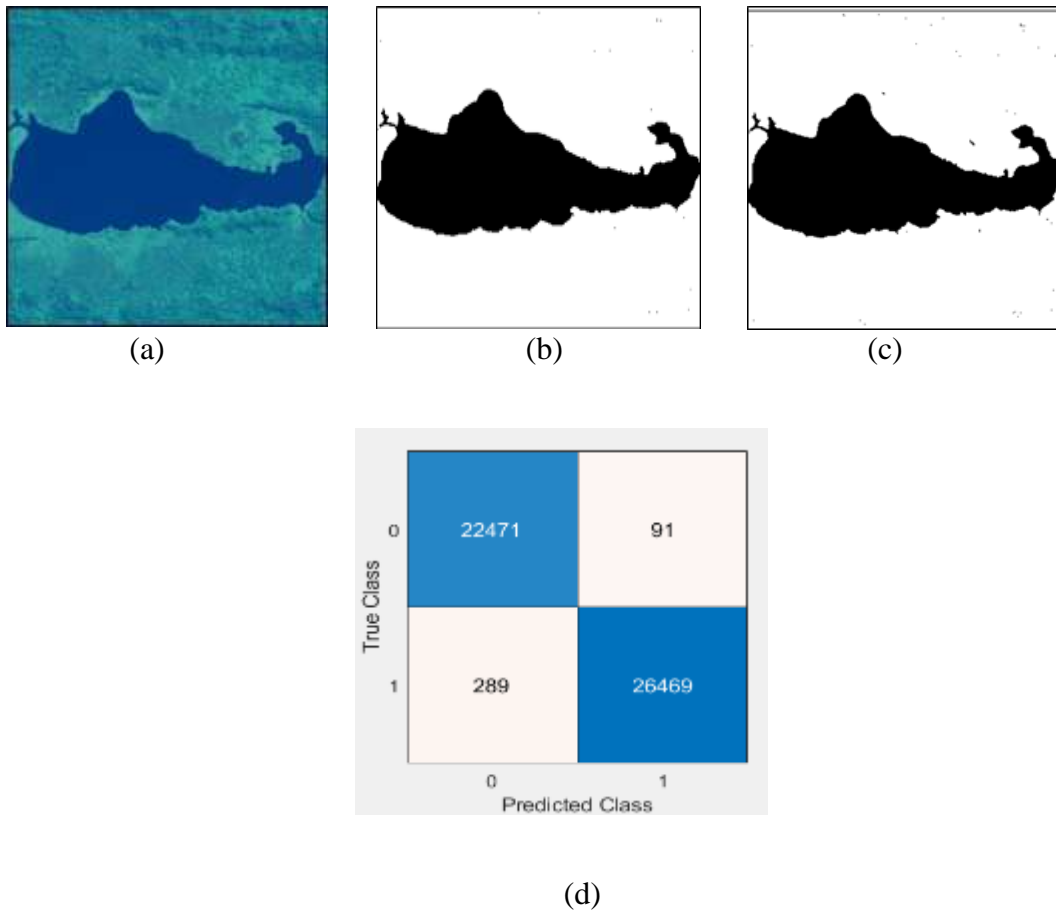


Figure III.14 Résultat de la segmentation par KPPV (image 103)

(a) Image originale ; (b) Image référence; (c) Image obtenue par KPPV, (d) matrice de confusion

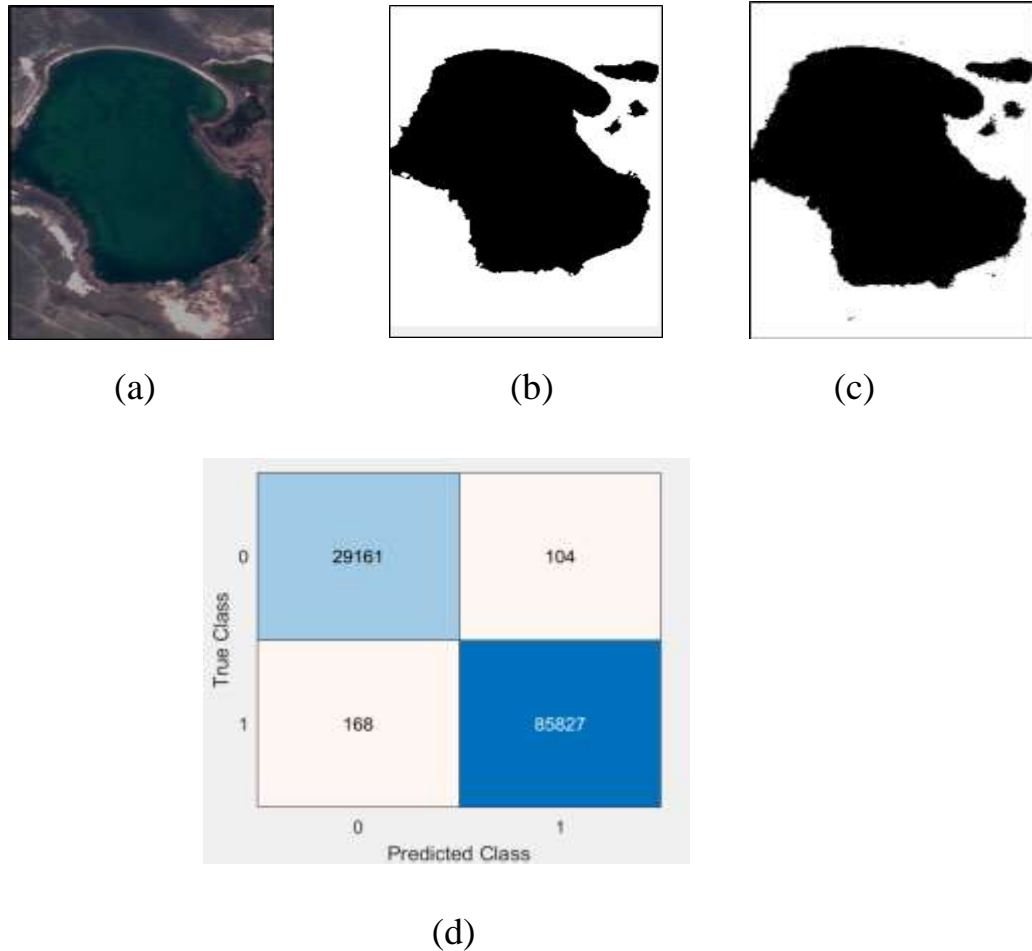


Figure III.15 Résultat de la segmentation par KPPV (image 102)

(a) Image originale ; (b) Image référence; (c) Image obtenue par KPPV, (d) matrice de confusion

III.8.3.2 Evaluation de la précision de la méthode KPPV

On remarque que pour cette méthode la précision est de 0.99 et Fmesure est aussi de 0.84, cette dernière prouve que la méthode KPPV est précise mais elle présente un rappel maximal de 0.74. La précision et le rappel nous donne une Fmesure de 0.84, Tableau III.2.

Tableau III.3 Métrique de la méthode KPP

	TP	TN	FP	FN	Précision	Rappel	Fmesure
IMAGE 182	85827	168	104	29161	0.99	0.74	0.84
IMAGE 103	2714	95	21	5090	0.99	0.34	0.5
IMAGE 102	26469	289	91	22471	0.99	0.54	0.69

Nous avons réunis les différents résultats des trois méthodes appliquées aux trois images dans le tableau III.4.

Tableau III.4 Récapitulation des métriques

Méthode	Image 182			Image 103			Image 102		
	RNA	SVM	KPPV	RNA	SVM	KPPV	RNA	SVM	KPPV
TP	22309	26498	85827	342771	2721	2714	22305	85861	26469
TN	26518	260	168	400346	88	95	26518	134	289
FP	253	329	104	5236	59	21	253	195	91
FN	240	22233	29161	2467	5052	5090	240	29070	22471
Précision	0.98	0.98	0.99	0.98	0.97	0.99	0.98	0.99	0.99
Rappel	0.98	0.5	0.74	0.99	0.35	0.4	0.98	0.74	0.54
Fmésure	0.98	0.6	0.84	0.97	0.51	0.5	0.98	0.84	0.69

Les représentations graphiques des trois métriques la précision, rappel et F mesure des trois images sont données respectivement par les figures ci-dessous.




Figure III.16 Les métriques pour l'image 182



Figure III.17 Les métriques pour l'image 103




Figure III.18 Les métriques pour l'image 102

Les résultats montrent que la méthode des réseaux de neurones artificiels est la plus efficace vu qu'elle offre la valeur maximale de Fmesure figure III.16, III.17 et III.18

III.9 Conclusion

On remarque que les résultats de la détection de l'eau par les trois méthodes sont prometteuses vu la précision globale obtenue. Les réseaux de neurones artificiels sont les plus robustes et les plus précis offrant une Fmesure maximale pour les trois

images. On note que les SVM et les KPPV sont faciles à mettre en œuvre et le temps d'apprentissage est plus faible que pour les RNA.

Conclusion générale

L'objectif de la détection d'eau à partir d'images satellitaires est généralement de cartographier et de surveiller les étendues d'eau à l'échelle régionale ou mondiale. Les objectifs principaux sont nombreux on cite: la surveillance et la gestion des ressources en eaux, la détection des inondation, l'étude des changement climatiques, analyse environnementale, ect. Dans ce contexte, ce mémoire vise à explorer et comparer l'efficacité de trois techniques de classification apprentissage automatique : la Machine à Vecteurs de Support (SVM), le K-Nearest Neighbors (KNN) et le Réseau de Neurones Artificiels (RNA). À travers une série d'expériences rigoureuses et d'analyses approfondies, nous avons évalué leurs performances sur notre jeu de données spécifique, en tenant compte de divers critères tels que la précision, le rappel, le score F1 calcul.

L'évaluation comparative approfondie des méthodes SVM, KNN et RNA, offrant des recommandations éclairées pour leur utilisation future en fonction des besoins spécifiques des applications. Les résultats obtenus et les analyses réalisées constituent une base solide pour orienter les décisions dans le domaine de la classification en apprentissage automatique, contribuant ainsi à l'avancement des connaissances et des pratiques dans ce domaine en constante évolution.

A travers cette étude, on remarque que la précision est de 0.98 et Fmesure est aussi de 0.98, pour l'algorithmr RNA, Aussi elle est de 0.99 pour l'algorithme des SVM et elle est de 0.99 pour l'algorithme KPPV. Les valeurs de Fmesure montre que l'algorithme RNA est le plus robuste et meilleur car elle est de 0.98 pour RNA et elle est de 0.84 pour l'algorithme SVM et l'algorithme KPPV

On remarque que les résultats de la détection de l'eau par les trois méthode sont prometteuses vu la précision global obtenu. Les réseaux de neurones artificielle sont les plus robuste et plus précis. On note que les SVM et les KPPV sonrt facile à mettres en oeuvre et le temps d'apprentissage est plus faible que pour les RNA.

Les résultats obtenues peuvent être améliorés en adoptant au vecteur des caractéristique une analyse en composante principales pour diminuer la taille du vecteurs d'entrées en éliminant les données corrélées et en ajoutant les attribus texturaux.

Références bibliographiques

- [1] Aude Nuscia Taïbi, Gérard Moguedet, Rachid Boukchina, F. Ababsa, A. Gaouar, F. Lakhdari, D. Dubost, D. Violleau, F. Picard-Bonnaud, D. Kirane, 'La ressource en eaux non conventionnelles facteur de développement en zone saharienne', Conférence internationale « Hydrologie des régions méditerranéennes et semi-arides », ENSA, Montpellier 1-4 avril 2003.
- [2] Syahaneim Marzukhi, Mohd Amirul Shafiq Mohamad Sidik, Haidawati Mohd Nasir, Zuraini Zainol, and Mohd Nazri Ismail. 'lood Detection and Warning System (FLoWS)'. In Proceedings of The 12th International Conference on Ubiquitous Information Management and Communication, Langkawi, Malaysia, January 5–7, 2018 (IMCOM '18), 4 pages. <https://doi.org/10.1145/3164541.3164623>
- [3] Füssel, H.-M. and van Minnen, J. G.: 2001, 'Climate impact response functions for terrestrial ecosystems', *Integr. Assess.* 2, 183–197.
- [4] Szeliski, 2010, *Computer Vision: Algorithms and Applications*, 2nd ed. 2022
- [5] Shapiro and Stockman, 2001 Shapiro, L.G. and Stockman, G.C. (2001) *Computer Vision*. Prentice Hall, Upper Saddle River.
- [6] LeCun et al., 2015, Deep learning, *Nature*, VOL 521, 2015, doi:10.1038/nature14539
- [7] Altman, I., & Low, S. M. (1992), *Place Attachment*. New York and London: Plenum Press. <https://doi.org/10.1007/978-1-4684-8753-4>
- [8] Russell and Norvig, 2020, *Artificial Intelligence A Modern Approach* Third Edition, *Artificial Intelligence* 175:935-937, DOI:10.1016/j.artint.2011.01.005
- [9] OGE Marques. *Practical Image and Video Processing Using MATLAB*. Florida Atlantic University (2011).
- [10] Diego Oliva, Mohamed Abd Elaziz, Salvador Hinojosa. *Metaheuristic Algorithms for Image Segmentation : Theory and Applications*. Springer
- [11] R.Gonzales., R.E Woods. *Digital image processing*. Edition Addison-Wesley (1993) USA. P.226-227
- [12] Karim Chabir. *Diagnostic de défauts des systèmes contrôlés via un réseau*. Autre [cs.OH]. Université Henri Poincaré - Nancy 1, 2011. Français. ffNNT : 2011NAN10044ff. fftel-01746194f

- [13] <https://hal.univ-lorraine.fr/tel-01750473> , consulté le 20.02.2024
- [14] Abdelaziz HABBA et Omar ISHAK, ‘La classification des images satellitaires par l'apprentissage profonde (deep learning)’, Mémoire de fin d'étude, en vue de l'obtention du diplôme de Master en informatique Option :Systèmes Intelligents, université d'Adrar, 2019.
- [15] Lettvin.J, Maturana.H, McCulloch.W, and Pitts.W. What the Frog's Eye Tells the Frog's Brain?Proceedings of the IRE, 47(11):1940–1951, Nov. 1959
- [16] D.C.Plaut, G. E. Hinton, Learning sets of filters using back-propagation, Computer Speech & Language, Vol.2, Issue. 1, pp. 35-61, 1987
- [17] Rumelhart.D.E and McClelland.J.L. Learning Internal Representations by Error Propagation. In Parallel Distributed Processing: Explorations in the Microstructure . *Cognition: Foundations. MITP, 1987*
- [18] Vapnik.V.N. The nature of statistical learning theory. Springer, 2000
- [19] Karush.W. Minima of functions of several variables with inequalities as side constraints.Master's thesis, Dept. of Mathematics, Univ. of Chicago, 1939.
- [20] Kuhn.H.W and Tucker.A.W. Nonlinear programming. In University of California Press,editor, 2nd Berkeley Symposium on Mathematical Statistics and Probabilistics, pages481– 492, 1951
- [21] Hamel.L. Knowledge discovery with support vector machines. Wiley Edition 2009
- [22] Shigeo.A. Support Vector Machines for Pattern Classification. Springer-Verlag London Limited, 2005
- [23] Guermeur.Y. Svm multiclass, théorie et applications. Habilitation à diriger des recherches, Université Henri Poincaré, France, 2007
- [24] Vapnik.V.N. Statistical Learning Theory. Edition Wiley, 1998
- [25] Alma'adeed. S, Higgins. C, Elliman. D : " Recognition of Off-Line Handwritten Arabic Words Using Hidden Markov Model Approach ". ICPR, University of Nottingham, 2002
- [26] Wanas. N. M, El-Sakka. M. R, Kamel. M. S : " Multiple Classifier Hierarchical Architecture for Handwritten Arabic Character Recognition ". Pattern Analysis and
- [27] Machine Intelligence Laboratory, Departement of Systems Design Engineering, University

- of Waterloo, Waterloo, Ontario Canada N2L-3G1, 1999.
- [28] Scholkopf.B and Smola.A.J. Learning with Kernels Support Vector Machines,Regularization, Optimization, and Beyond. MIT Press, 2002
- [29] Abdelhamid, D. “Utilisation des méthodes Support Vector Machine (SVM) dans l’analyse des bases de données”. Thèse de docteur en science. Option informatique. Université Mohamed Khider – Biskra. 2012.
- [30] Schwenker.F. Hierarchical support vector machines for multi-class pattern recognition. In Knowledge-Based Intelligent Engineering Systems and Allied Technologies, 2000. Proceedings. Fourth International Conference on, volume 2, pages 561–565. IEEE, 2000.
- [31] Seo.N. A comparison of multi-class support vector machine methods for face recognition. Technical report, The University of Maryland, Dec 2007.
- [32] Steinwart.I and Christmann.A. Support Vector Machines. Springer, 2008.
- [33] Hannane. A. M., "Conception d'un système hybride entre la Méta heuristique Electromagnétique et l'algorithme de colonie de fourmis pour la classification des images satellitaires ", mémoire de Magistère en informatique (option: Télédétection, Analyse et Traitement Informatique des Données Spatiale). Université des sciences et de la technologie d'Oran Mohamed Boudiaf, Oran, Algérie, 2020.
- [34] Yi Yang and Shawn Newsam, "Bag-Of-Visual-Words and Spatial Extensions for Land-Use Classification," ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems (ACM GIS), 2021.