

N° d'ordre : 3356

# THESE

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

*Structure de Recherche : Laboratoire Conception et Systèmes (Electronique, Signaux et Informatique)*

*Discipline : Sciences de l'ingénieur*

*Spécialité : Electronique et Informatique*

*Présentée et soutenue le : 21/12/2020 par :*

**Mohammed Amine AZZAoui**

***Contribution à la segmentation d'images satellitaires à haute résolution avec une approche d'apprentissage machine. Application aux dunes de sable Barkhanes***

## JURY

<i>Mourad ELBELKACEMI</i>	<i>PES, Faculté des Sciences, Université Mohammed V, Rabat</i>	<i>Président</i>
<i>Lhoussaine MASMOUDI</i>	<i>PES, Faculté des Sciences, Université Mohammed V, Rabat</i>	<i>Directeur de Thèse</i>
<i>Brahim ELKHALIL CHAOUKI</i>	<i>PES, Ecole Nationale des Sciences Appliquées d'Agadir, Université Ibn Zohr, Agadir</i>	<i>Co-Directeur de Thèse</i>
<i>Mourad GHARBI</i>	<i>PES, Faculté des Sciences, Université Mohammed V, Rabat</i>	<i>Rapporteur / Examineur</i>
<i>Hicham ELBELRHITI</i>	<i>PH, Institut Agronomique et Vétérinaire Hassan II, Rabat</i>	<i>Rapporteur / Examineur</i>
<i>Majid HADRI</i>	<i>PH, Faculté des Sciences, Université Mohammed V, Rabat</i>	<i>Rapporteur / Examineur</i>
<i>Ahmed ROUKHE</i>	<i>PES, Faculté des Sciences, Université Moulay Ismail, Meknès</i>	<i>Examineur</i>

## Dédicace :

A mes parents, mon épouse et mes frères  
pour leur patience, soutien et encouragements.

A la mémoire de ceux qui ont découvert, de ceux qui ont enseigné  
et de ceux qui ont partagé leur savoir et illuminé le monde d'espoir.

## Avant-propos

Je tiens tout d'abord à remercier Dieu. Ensuite, c'est avec un grand plaisir que je réserve cette page, en signe de gratitude et de reconnaissance à tous ceux qui m'ont aidé à la réalisation de ce travail.

Ce travail a été réalisé au sein du Laboratoire Conception et Systèmes (Electronique, Signaux et Informatique), sous la Direction du Pr.Lhoussaine MASMOUDI et le co-encadrement du Pr.Ibrahim Elkhalil CHAOUKI.

Je remercie le doyen de la Faculté des Sciences de Rabat et le directeur de l'école doctorale de m'avoir donné l'opportunité de poursuivre mes études à cette faculté.

Je tiens à exprimer ma reconnaissance à Monsieur Lhoussaine MASMOUDI, Professeur à la Faculté des Sciences de l'Université Mohammed V, Rabat, en tant que Directeur de thèse pour m'avoir accueilli au sein de son équipe, pour ses directives scientifiques, pédagogiques et même personnelles pour lesquelles je lui suis hautement redevable.

Je tiens tout particulièrement à remercier Monsieur Ibrahim Elkhalil CHAOUKI, Professeur à l'Ecole Nationale des Sciences Appliquées d'Agadir de l'Université Ibn Zohr, en tant que co-Directeur de thèse, pour son aide, son soutien permanent, sa grande disponibilité, son enthousiasme et sa bienveillance dont il a fait preuve durant toutes ces années. Merci de m'avoir écouté, compris et encouragé tout au long de l'encadrement.

Mes plus sincères remerciements vont à tous les membres du jury d'avoir accepté d'évaluer ce travail, et de prendre part à cette thèse. Tout d'abord, Monsieur Mourad ELBELKACEMI, Professeur à la Faculté des Sciences de l'Université Mohammed V, Rabat qui m'a fait l'honneur de présider mon jury de thèse.

Je remercie Monsieur Mourad GHARBI, Professeur à la Faculté des Sciences de l'Université Mohammed V, Rabat, d'avoir accepté d'être rapporteur et examinateur de cette thèse.

J'adresse mes plus vifs remerciements à Monsieur Hicham ELBELRHITI, Professeur Habilité à l'Institut Agronomique et Vétérinaire Hassan II, Rabat, d'avoir accepté d'être rapporteur et examinateur de cette thèse, et d'avoir aussi accompagné ce travail depuis sa phase initiale.

Je remercie Monsieur Majid HADRI, Professeur Habilité à la Faculté des Sciences de l'Université Mohammed V, Rabat, d'avoir accepté d'être rapporteur et examinateur de cette thèse.

Je remercie aussi Monsieur Ahmed ROUKHE, Professeur à la Faculté des Sciences de l'Université Moulay Ismail, Meknès, d'avoir accepté d'être examinateur de cette thèse.

Je remercie chaleureusement mes collègues de travail, et particulièrement Dr. Manare ADNANI, Mr. Abdelkrim ABENAY et Mr. Ayoub EZZAKI pour leur aide et soutien.

Je ne saurais oublier dans mes remerciements tout le corps professoral du Laboratoire Conception et Systèmes (Electronique, Signaux et Informatique), leur persévérance garantit une réelle évolution de la recherche scientifique.

Enfin, tous ceux et celles qui ont contribué de près ou de loin à l'accomplissement de ce travail trouvent l'expression de mes remerciements les plus chaleureux.

Mohammed Amine AZZAOUI

# Résumé

L'étude des dunes de sable est essentielle pour comprendre et prévenir le phénomène de l'ensablement. La collecte de données sur le terrain est une tâche ardue sachant le nombre important de dunes. Nous avons contribué avec une nouvelle approche automatisant la collecte de données des dunes à partir d'images satellitaires par l'apprentissage automatique pour la segmentation. Nous nous intéressons aux dunes Barkhanes car elles sont les plus rapides. Leur segmentation pose plusieurs des problèmes dus à la variabilité de leur luminosité, taille, orientation et forme non rigide, ce qui ne permet pas de faire appel aux méthodes classiques de traitement d'images. Aussi, les méthodes standard reposant sur le calcul d'une signature spectrale ne permettent pas de différencier les dunes, du lit de sable et des roches présentant des compositions minérales similaires. Pour surmonter ces difficultés, nous avons exploité la texture de l'image avec des descripteurs et des indicateurs statistiques, obtenant ainsi de bons résultats dans les zones texturées. Nous avons amélioré leur segmentation avec une approche d'apprentissage machine combinant un classificateur hiérarchique en cascade pour la détection des positions des barkhanes avec une nouvelle variante du modèle de forme active que nous avons introduite pour réaliser la correspondance des contours. Aussi, nous avons développé un modèle d'allométrie des Barkhanes. Enfin, nous avons généralisé notre solution pour le cas des Barkhanes en collision, présentant des formes erratiques, en introduisant l'utilisation du transfert d'apprentissage, variante du Deep Learning. Nos méthodes ont été testées sur des images satellite IKONS à haute résolution, affichant l'un des plus grands couloirs de dunes Barkhanes, localisé dans la région de Laayoune, au Maroc, ainsi que sur une image du satellite MRO, affichant un ensemble de dunes Barkhanes sur Mars. Les résultats expérimentaux étaient très satisfaisants en précision et en robustesse.

Mots clés: Segmentation d'image, détection d'objets, Apprentissage Machine, Imagerie Satellitaire à Haute Résolution, Télédétection, dunes barkhanes.

# Abstract

The study of sand dunes is essential to understand and prevent the desertification phenomenon. Gathering data from the field is a labor intensive task, as deserts contain a large number of moving sand dunes. In this work, we contributed with a novel approach to automate data collection of sand dunes, from High Resolution Satellite Images, using machine learning for image segmentation. We focused on Barchan dunes as they were the fastest moving sand dunes. We faced many obstacles to detect and segment barchans due to the variability of their luminosity, size, orientation and non-rigid shape, which makes classical image processing techniques ineffective. Methods based on spectral signature were unsuccessful in distinguishing between dunes, bedrock and surrounding sand having similar mineral composition. To overcome these issues, we started by taking advantage of image texture using descriptors in addition to statistical indicators, which allowed us to get good results in textured areas. We improved their segmentation using a Machine Learning approach in which we combined a hierarchical cascade classifier for the detection of Barchans locations, with a new variation of Active Shape Model which we introduced for contour matching. Moreover, we developed a new model to automate the calculation of Barchans dunes allometry. Finally, to further generalize our research, we wanted to take into account colliding Barchans, which have erratic shapes, which could not be modelled using classical approaches. Thus, we introduced the use of Transfer Learning as a variation of Deep Learning to achieve the detection of Barchans dunes collisions. Our methods were tested on an IKONS high resolution satellite image, displaying one of the largest Barchans dunes corridor in the region of Laayoune, Morocco, and also on an MRO image, displaying a set of Barchans dunes in Mars. The experimental results were satisfying both in accuracy and robustness.

Keywords : Image segmentation, object detection, Machine Learning, High resolution satellite imagery, Remote sensing, Barchans dunes.

## Table des figures

Fig 1 : Ensablement des routes et des constructions dans la région de Laayoune .....	14
Fig 2 : Image aérienne d'un ensemble de dunes barkhanes.....	15
Fig.3 : Moyens de lutte contre l'ensablement.....	16
Fig.4 : Modèle basique d'apprentissage machine.....	20
Fig.5 : Courbes d'apprentissage d'un modèle simple et complexe.....	21
Fig.6: Carte de l'apprentissage machine.....	23
Fig.7 : Illustration d'une dune barkhane.....	29
Fig. 8 : La classification par proéminence.....	37
Fig.9 : Illustration des résultats de la segmentation à chaque étape du traitement où chaque image correspond à la clé indiquée précédemment.....	39
Fig.10 : Modèle d'allométrie des dunes barkhanes.....	46
Fig 11 : Processus complet de détection, segmentation et allométrie des barkhanes.....	48
Fig 12 Echantillon de la base de données des images d'apprentissage.....	50
Fig 13 Alignement des contours par analyse de Procrustes.....	52
Fig.14 : Exemple de 2 modes différents de barkhanes.....	54
Fig.15 : Convergence de la mise en correspondance de contour.....	55
Fig.16 : Le processus de détection, segmentation de contours et de calcul de l'allométrie des dunes barkhanes.....	56
Fig.17 : Exemple de corrélation entre les mesures d'allométrie des dunes : $f(w) = L$ .....	57
Fig.18 : Exemple de corrélation entre les mesures d'allométrie des dunes : $f(ih) = w$ .....	58

Fig.19 : Exemple de corrélation entre les mesures d'allométrie des dunes : $f(w)=S$ .....	58
Fig.20 : Exemple de corrélation entre les mesures d'allométrie des dunes : $f(w) = h_1+h_2$ .....	59
Fig.21 : Mesures des directions géométriques des dunes de sable barkhanes.....	60
Fig.22 Architecture du modèle Deep Learning AlexNet.....	65
Fig.23 : De gauche à droite : image originale, application de l'histogramme d'égalisation, application du filtre bilinéaire .....	68
Fig.24 Segmentation des combinaisons de bandes, et échantillon d'évaluation.....	70
Fig.25 Entraînement du Transfert d'Apprentissage.....	72
Fig.26 Echantillons d'images satellitaires représentant les 3 classes utilisées.....	73

## Liste des tableaux

Tab 1. Informations sur les caractéristiques de l'image MRO.....	32
Tab.2 : Résultats de la segmentation et temps d'exécution.....	37
Tab 3 : Matrice de confusion de la détection des barkhanes.....	51
Tab 4 : Résultats de l'ACP des contours des dunes.....	53
Tab.5 : Résolutions spatiales et spectrales de l'image satellitaire IKONOS utilisée.....	63
Tab.6 : Evaluation de la segmentation des différentes combinaisons de bandes.....	71

# Table des matières

Remerciements

Résumé-Abstract

Table des figures

Liste des tableaux

Introduction générale .....	12
Contexte de la thèse.....	12
Problématique.....	14
Synthèse des contributions.....	17
Organisation du manuscrit.....	18
Chapitre 1 : Apprentissage machine et imagerie satellitaire.....	20
1.1 Bases de l'apprentissage machine.....	20
1.1.1 Un modèle de l'apprentissage machine.....	20
1.1.2 Types d'apprentissage machine.....	21
1.1.3 La courbe d'apprentissage.....	21
1.2 Une synthèse des approches d'apprentissage machine.....	22
1.3 Apprentissage machine pour la segmentation d'images satellitaires .....	25
Chapitre 2: La segmentation de texture des Barkhanes.....	28
2.1 Introduction.....	28
2.2 Méthodologie de segmentation de dunes barkhanes.....	30
2.2.1 Imagerie satellitaire et dunes de sable.....	30
2.2.2 L'imagerie satellitaire à haute résolution MRO.....	31
2.2.3 Les descripteurs de texture de Haralick.....	32
2.2.4 Le test de Kolmogorov - Smirnov.....	33
2.2.5 Les descripteurs de SURF et MSER pour les barkhanes.....	34
2.3 Approche proposée pour la fusion des descripteurs de segmentation des barkhanes.....	35

2.4	Résultats expérimentaux.....	36
2.5	Conclusion.....	40
	Chapitre 3: La segmentation de contours et l'allométrie.....	41
3.1	Introduction.....	41
3.2	Les méthodes de détection, segmentation et allométrie des barkhanes.....	42
3.2.1	Préparation de l'image satellitaire à haute résolution IKONOS.....	42
3.2.2	La détection des barkhanes par cascade hiérarchique de classificateurs.....	42
3.2.3	Segmentation de contours par ASM.....	44
3.2.4	Les mesures d'allométrie des barkhanes.....	45
3.3	Intégration de détection, segmentation et allométrie .....	47
3.4	Résultats obtenus.....	49
3.5	Conclusion.....	61
	Chapitre 4 : La détection de collision de dunes Barkhanes et le transfert d'apprentissage.....	62
4.1	Introduction.....	62
4.2	Détection, segmentation et allométrie des barkhanes ...	62
4.2.1	L'amélioration d'image et la fusion des bandes multispectrales et panchromatiques.....	62
4.2.2	La segmentation par clustering pour isoler le couloir de dunes.....	64
4.2.3	Le Transfert d'Apprentissage comme variation du Deep Learning.....	64
4.3	Résultats obtenus.....	68
4.4	Conclusion.....	73
	Conclusion générale.....	75
	Bibliographie.....	78
	Annexe.....	85
	Publications.....	87

# Introduction générale

## Contexte de la thèse

L'être humain a la capacité unique de comprendre son environnement en traitant et en interprétant l'information visuelle de haut niveau à partir de données sensorielles de bas niveau à un rythme ultra rapide. La Perception visuelle humaine a beaucoup suscité l'intérêt des scientifiques qui étudient, depuis plusieurs décennies le fonctionnement du système visuel pour le simuler dans des applications de la vision par ordinateur. Ce domaine de recherche a pour but de développer une interprétation visuelle du monde réel en utilisant des algorithmes qui extraient de l'information représentative à partir des images.

Parmi les approches de vision par ordinateur on trouve le problème de segmentation d'objet, cette opération consiste à extraire l'objet d'intérêt à partir d'une image. Ainsi, la segmentation d'image constitue une étape fondamentale dans la plupart des systèmes de vision par ordinateur. D'ailleurs, une grande variété des techniques ont été proposées pour extraire l'objet à partir du fond de l'image. La télédétection utilisant l'imagerie satellitaire n'en est pas une exception, on retrouve le problème de segmentation d'objet, cette opération consiste à extraire l'objet d'intérêt à partir d'une image. Ainsi, la segmentation d'image constitue une étape fondamentale dans la plupart des systèmes de vision par ordinateur. D'ailleurs, une grande variété des techniques ont été proposées pour extraire l'objet à partir du fond de l'image. Les premières techniques ont commencé par explorer l'extraction de contours et la représentation d'objets en polygones (G. Matheron 1967). Par la suite, ce domaine a vu le développement de modèles mathématiques plus poussés permettant de prendre en compte les textures et les ombrages, ainsi que les modèles de contours. Plus tard, le développement des descripteurs d'images a pris de l'essor, ainsi que l'application de méthodes statistiques diverses, et plus récemment l'Apprentissage Machine, qui inclut le Deep Learning Bengio 2015.

L'apprentissage machine, parallèlement à l'apprentissage humain, vise à construire un modèle permettant d'accomplir une tâche précise, nécessitant de s'adapter progressivement au problème. Cette approche itérative combine des modèles statistiques ainsi que des algorithmes, afin d'approximer une fonction objectif inconnue, à partir de données qui sont annotées dans le cas de l'apprentissage supervisé, et non annotées dans le cas de l'apprentissage non supervisé. Le point fort de ces méthodes est leur propre auto-évaluation, qui consiste à valider leur résultat en utilisant des données de validation et de test. Leur contexte d'application est large car ils permettent d'apporter des solutions à des problèmes non linéaires. La vision par ordinateur se trouve être parmi les domaines les plus complexes, étant donné la difficulté d'extraction d'informations fiables à partir d'images et notamment d'images satellitaires.

La télédétection avec l'imagerie satellitaire a des avantages considérables dans l'étude de phénomènes à grande échelle. Elle permet d'apporter une information globale, tout en restant non invasive. Aussi, avec l'augmentation de la résolution spatiale des images, la précision des informations augmente. L'imagerie satellitaire a été utilisée entre autres dans le domaine de la défense et le renseignement, dans l'économie et les marchés boursiers pour suivre les productions agricoles, dans la planification urbaine et la gestion de risques d'inondations, ainsi que dans l'étude de phénomènes environnementaux divers. Notre travail s'inscrit dans l'étude d'un phénomène de la désertification, et plus particulièrement le mouvement des dunes de sable dans le désert.

## Problématique

Selon les Nations Unies, plus de 250 millions d'habitants et 110 pays sont affectés par la désertification UNCCD 2008. La progression des dunes de sable a en effet des conséquences économiques et sociales sur les populations locales. Le sable peut éventuellement couvrir des routes, des convoyeurs, des maisons et des champs, ralentissant l'activité économique, présentant des risques pour les usagers de la route, créant des tensions sociales entre petits agriculteurs, et menaçant les zones urbaines concernées [Fig.1].



Fig 1 : Ensablement des routes et des constructions dans la région de Laayoune

Il existe plusieurs types de dunes de sable mais les plus rapides et donc les plus dangereuses sont les dunes en forme de croissant appelées Barkhanes.



Fig 2 : Image aérienne d'un ensemble de dunes barkhanes

Notre problématique consiste à les détecter et à les segmenter sur des images satellitaires à haute résolution. En effet, leur forme caractéristique est un atout pour les distinguer, cependant, elle présente aussi des défis car il s'agit d'un objet présentant une luminosité dépendant de la réflexion du soleil sur sa surface incurvée, aussi, il se présente sous différentes tailles selon sa maturité, et présente des orientations variables selon la direction du vents. De plus, il s'agit d'une forme non rigide qui subit des perturbations constantes dues aux obstacles naturels et artificiels qu'il trouve sur son chemin, comme par exemple des rochers et des routes. Enfin, puisque les dunes de petite taille ont une vitesse supérieure aux dunes de grande taille, les collisions de dunes sont fréquentes et produisent des objets dont la forme chaotique, est totalement différente de sa forme caractéristique originale, rajoutant ainsi un niveau de complexité supplémentaire.

Face à ces défis, les méthodes classiques de traitement d'image utilisées en imagerie satellitaire comme les signatures spectrales sont souvent inefficaces pour différencier le sable (Particules de 0,075 à 4,75 mm) des dunes, du lit de sable ou de la roche ayant une composition minérale similaire Hugenholtz et al. 2012. Les géologues et les spécialistes étudiant ce phénomène ont par conséquent recours à une approche manuelle longue et fastidieuse, où les dunes sont annotées manuellement une par une. Nous apportons des réponses face à ce problème en introduisant des méthodes d'apprentissage machine et de vision par ordinateur dans la détection, la segmentation et l'extraction automatisée d'informations des dunes de sable de type Barkhane.

Il existe actuellement quelques solutions pour ralentir le phénomène de l'ensablement comme l'utilisation de plantes pour retenir le sable, ou au contraire, utiliser l'effet venturi pour accélérer le sable sur les routes, ou encore recourir au déblayement (Fig.3)



Fig.3 : Moyens de lutte contre l'ensablement

L'objectif de ce travail n'est pas de proposer des solutions en soi mais est d'automatiser la collecte des données en vue de permettre aux géologues, urbanistes et autres spécialistes de mieux comprendre le phénomène et ainsi de proposer des solutions à termes contre le problème de l'ensablement.

## Synthèse des contributions

Pour résoudre les problèmes cités ci-avant, nous avons proposé trois contributions pour la segmentation de dunes Barkhanes à partir d'images satellitaires à haute résolution et qui peuvent être résumées par :

Segmentation des dunes dans des images satellitaires à très haute résolution (Azzaoui et al. 2016). Ce premier travail présente une approche basée sur la combinaison de plusieurs descripteurs: Nous avons éliminé une partie de l'arrière-plan en exploitant la texture de l' image en utilisant une présélection des descripteurs de Haralick, basée sur le test statistique de Kolmogorov-Smirnov, puis nous avons affiné la segmentation des dunes en utilisant une approche multi échelle combinant les descripteurs de région MSER et les détecteurs SURF avec une validation croisée. La précision des résultats obtenus était très satisfaisante sur l'image satellitaire MRO qui représentait un groupe de dunes Barkhanes sur la surface Mars. Cependant, nous lui avons trouvé des limitations dans le cas des images IKONOS où les bordures des dunes ne se distinguaient pas facilement du terrain sablonneux.

Segmentation des contours de dunes et calcul de leur allométrie (Azzaoui et al. 2019a). Cette approche vise à pallier aux limitations de l'approche précédente, afin de permettre la segmentation de contours des dunes, mais aussi, les utiliser pour automatiser le calcul de l'allométrie des Barkhanes. Nous avons utilisé une approche à trois niveaux basée sur l'apprentissage machine qui consiste à détecter directement les dunes en utilisant une cascade hiérarchique de classificateurs, se reposant sur les ondelettes de Haar. Puis, une fois les dunes isolées, on procède à l'apprentissage d'un modèle de contour actif, basé sur une analyse

de Procrustes, une réduction de dimensionnalité ACP, et nous avons introduit une amélioration de cette méthode qui consiste à utiliser des descripteurs SIFT avec un classificateur SVM pour la correspondance de contour. Enfin, nous avons mis à contribution les contours détectés et introduit un modèle d'allométrie normalisé qui permet de calculer les largeurs, direction, largeur des cornes et autres caractéristiques morphologiques des dunes barkhanes. Enfin, nous avons exploré les corrélations spécifiques de ces mesures dont les résultats statistiques ont été confirmés par les études présentes dans la littérature présentant des mesures faites par des géologues sur le terrain.

Détection des collisions des dunes barkhanes en utilisant un Transfert d'Apprentissage (Azzaoui et al. 2020). Dans cette contribution, nous sommes allés plus loin dans la généralisation de notre solution. En effet, après avoir réussi à segmenter les dunes barkhanes, nous avons constaté que lors des collisions des dunes, celles-ci présentent sur l'image satellitaire, des formes très irrégulières. Pour les isoler, nous avons introduit l'utilisation d'une variante du Deep Learning appelée Transfert d'Apprentissage, et nous l'avons combinée avec un partitionnement basée sur la fusion des données multispectrales et panchromatiques. Les résultats ont été très satisfaisants et nous avons ainsi pu traiter l'ensemble des dunes Barkhanes présentes sur l'images satellitaire à haute résolution, tout en apprenant à utiliser et à combiner les points forts des différents méthodes d'apprentissage machine en développant une réflexion sur leur fonctionnement.

## Organisation du manuscrit

Ce document décrit l'ensemble des travaux menés dans le cadre de cette thèse sur segmentation d'images satellitaires de haute résolution en utilisant l'apprentissage machine. Application aux dunes de sable de type barkhanes. Il comporte quatre chapitres décrits comme suit :

Le premier chapitre propose un tour d'horizon des modèles et des principes de l'apprentissage machine. Nous définissons les bases de l'apprentissage à partir de données, présentons les différentes techniques selon plusieurs catégories. Leurs avantages et défauts sont discutés.

Le deuxième chapitre est consacré à notre première contribution proposée pour la segmentation des dunes en utilisant les descripteurs de texture et de région avec des classificateurs statistiques.

Dans le troisième chapitre, nous avons amélioré l'approche de segmentation en utilisant une cascade hiérarchique et en introduisant une nouvelle variation du modèle de forme actif. Nous avons ainsi extrait les contours et nous avons par la suite introduit un modèle d'allométrie des dunes qui nous a permis de dégager des résultats statistiques confirmés.

Le quatrième et le dernier chapitre est notre contribution de segmentation concernant les collisions de dunes en utilisant une fusion des informations spatiales et spectrales de l'image satellitaire et en introduisant l'utilisation d'un Transfert d'apprentissage basé sur le Deep Learning pour la détection des collisions.

La conclusion générale présente un bilan faisant à la fois la synthèse de nos travaux de recherche qui ont porté sur la segmentation et l'apprentissage machine, ensuite ouvre des perspectives de recherche sur les méthodes proposées.

# Chapitre I : Apprentissage machine et imagerie satellitaire

## 1.1 Bases de l'apprentissage machine

L'objectif de cette partie est d'introduire de manière succincte les notions de base d'apprentissage machine qui sont utilisées par la suite dans ce travail pour la segmentation des dunes barkhanes.

### 1.1.1 Un modèle de l'apprentissage machine:

Le modèle suivant introduit par (Abu-Mostafa 2012) permet d'illustrer les composants de l'apprentissage (Fig.4)

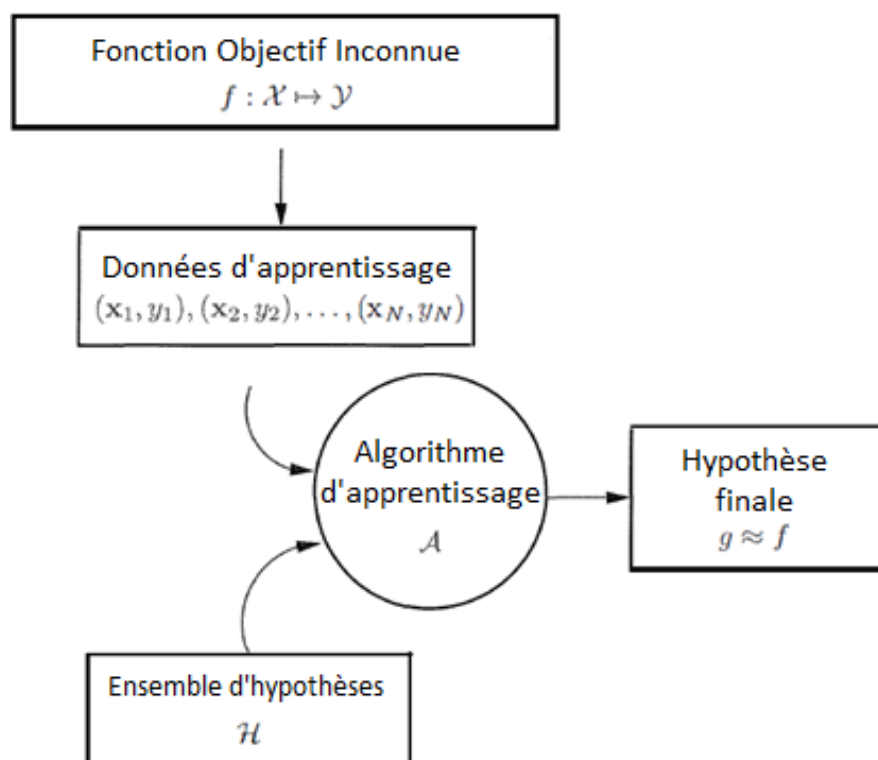


Fig.4 : Modèle basique d'apprentissage machine

On a besoin d'approximer une fonction objectif qui nous est

inconnue. Nous ne possédons qu'un ensemble de couples de points  $(x,y)$  qui nous donnent une idée sur cette fonction. Nous réservons un sous-ensemble de ces données, appelé ensemble de test, pour évaluer si notre approximation est correcte. De manière itérative, nous utilisons un algorithme qui va trouver parmi un ensemble d'hypothèses celle qui offre la meilleure approximation possible de la fonction objectif. Nous parlons ainsi d'apprentissage.

### 1.1.2 Types d'apprentissage machine:

Il existe plusieurs types d'apprentissage machine qui s'adaptent à différents problèmes et qui sont définis principalement par la nature des données utilisées (Shagan 2020) et qui sont l'apprentissage supervisé, non-supervisé et par renforcement. Dans le premier, nous disposons d'un label, pour le second, aucun label et pour le dernier, nous disposons d'un score pour chaque (entrée, sortie).

### 1.1.3 La courbe d'apprentissage :

Afin d'évaluer l'apprentissage, on se base sur les courbes d'apprentissage. Elles montrent en fonction des données utilisées l'évolution des erreurs Internes et Externes correspondant respectivement à  $E_{in}$  et  $E_{out}$ .




Fig.5 : Courbes d'apprentissage d'un modèle simple et complexe

Pour le modèle simple les erreurs convergent plus rapidement, mais elles convergent vers une erreur qui est plus grande, et donc la performance finale est inférieure à celle où converge le modèle complexe (Perlish 2011).

Dans les deux cas de modèle simple et de modèle complexe, ce qui empêche notre hypothèse de s'ajuster aux données est le bruit. On peut décomposer ce bruit en deux parties, le bruit stochastique et le bruit déterministe. Le premier bruit correspond à la qualité des données qui sont par exemple bruitées à cause des incertitudes de l'instrument de mesure.

Le second type de bruit découle de l'incapacité du modèle à s'ajuster aux données. Par exemple un modèle simple comme un polynôme de degré 2, ne pourra pas s'ajuster correctement à des données générées par une fonction objectif de complexité supérieure, comme un polynôme de degré 5. Aussi efficace que soit l'algorithme, il y a une limite imposée par le modèle lui-même.

## 1.2 Une synthèse des approches d'apprentissage machine :

L'apprentissage machine peut être perçu selon 4 principaux axes (Fig.6). Nous avons discuté des paradigmes, des aspects théoriques et de quelques méthodes et modèles dans les sections précédentes. Mais cela ne réponds pas à la question de savoir quel modèle utiliser. En effet, il n'existe pas de théorème absolu permettant de définir quel modèle d'apprentissage machine choisir pour accomplir une tâche donnée. Nous pouvons être néanmoins guidés en analysant la nature de cette tâche et en comprenant bien évidemment les avantages et limitations des modèles d'apprentissage machine.

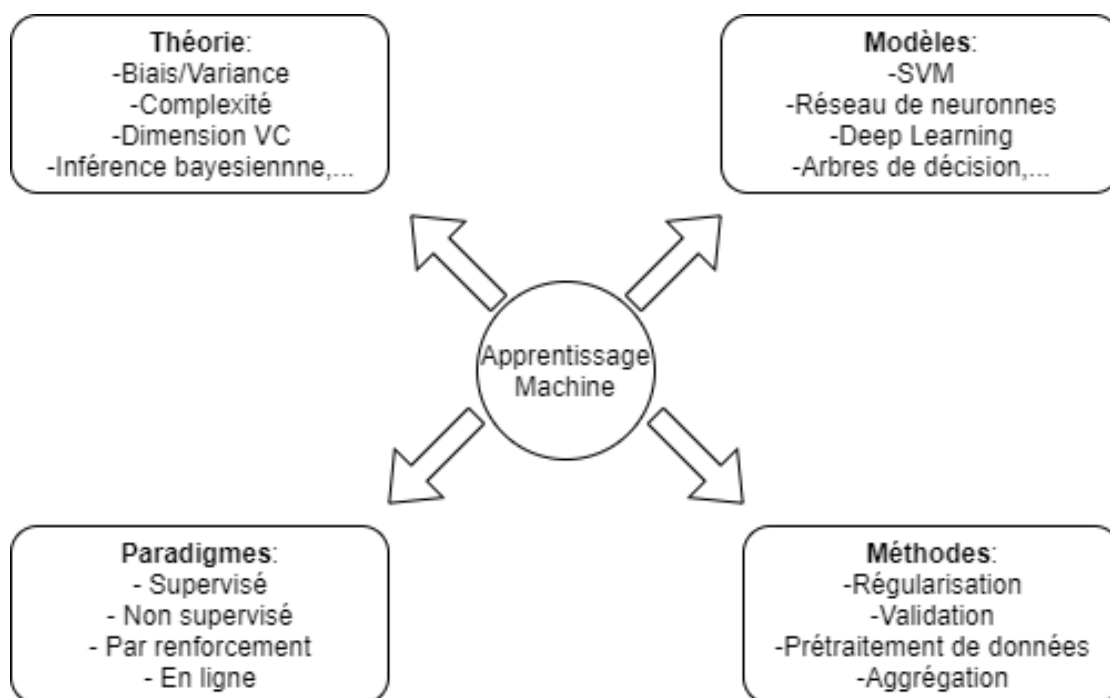


Fig.6: Carte de l'apprentissage machine

Nous commençons par identifier les trois classes principales de tâches, à savoir la régression, la classification et le clustering. La régression consiste à prédire des variables supposément continues. Le modèle souvent utilisé pour cette tâche est la régression linéaire qui cherche à trouver l'hyperplan optimal qui s'ajuste aux données. Il est utilisé comme base par d'autres modèles comme LASSO, qui pour l'améliorer, utilise la régularisation, dont la fonction est de pénaliser les coefficients trop importants, afin de réduire le risque de surapprentissage. La régression linéaire est plutôt simple à comprendre et son modèle peut être mis à jour facilement avec une descente de gradient. Cependant, ce modèle ne capture pas facilement les non linéarités. Les arbres de décision quant à eux, opèrent un apprentissage hiérarchique en découpant les données en branches de sorte à maximiser le gain d'information. Cette structure permet aux arbres de décision d'apprendre les relations non linéaires présentes dans les données (KamHo 1995). Les Random Forests (RF)

et Gradient Boosted Trees (GBM) sont deux variants d'arbres de décision. L'avantage de ces méthodes est leur robustesse face aux *outliers* et leur capacité à apprendre les relations non linéaires. Si ils ne sont pas contrôlés, ces modèles peuvent néanmoins surapprendre les données car elles continuent de découper les données jusqu'à les mémoriser. Le Deep Learning est un réseau de neurones multicouches qui utilise des mécanismes comme les convolutions, le drop out qui lui permettent d'apprendre à partir de données de grande dimension. Il est très efficace pour résoudre les problèmes de vision par ordinateur, et évite de passer par l'ingénierie des caractéristiques (*feature engineering*). Cependant, ils requièrent de très grandes quantités de données. La seconde classe de tâches est la classification qui consiste à modéliser et prédire des variables catégoriques. La régression logistique est souvent utilisée à cet effet car elle permet une interprétation probabiliste, mais elle est aussi limitée lorsque les décisions sont non linéaires. Les arbres de classification font partie des arbres de décision et ont des caractéristiques similaires. Il y a bien sûr le Deep Learning dont la principale application est la classification. Nous considérons aussi les Machines à Vecteurs de Support (SVM) qui peuvent utiliser le mécanisme des noyaux (Kernels) qui consiste à calculer la distance entre deux observations (Vapnik 1982). SVM permet de modéliser les décisions non linéaires, et est robuste contre les *outliers*. Cependant, il ne s'adapte pas aussi bien aux grandes quantités des données, et requiert d'être correctement configuré. La classification naïve bayésienne est un algorithme simple basé sur les probabilités conditionnelles et le comptage. Le modèle est une table de probabilités. Il est dit naïf, car il considère que les données sont indépendantes, ce qui rarement le cas dans la réalité et pourtant, le modèle fonctionne correctement pour ces données, mais du à sa simplicité, les résultats retournés par les méthodes citées précédemment sont souvent meilleurs. La troisième classe de tâche

est le clustering, qui consiste à grouper les données. Parmi les modèles les plus connus, il y a K-Means qui se base sur les distances géométriques entre les points de données pour constituer des groupes. Il est simple et très pratique pour le prétraitement de données. Cependant, il faut spécifier le nombre de clusters qui sont souvent dépendants de l'application. L'affinité de propagation est un autre modèle qui se base sur la distance de graphes entre les points de données. L'utilisateur n'a pas à spécifier le nombre de clusters mais doit par contre spécifier les hyperparamètres. Il est relativement lent et ne s'adapte pas facilement aux grandes quantités de données. Le modèle DBSCAN qui constitue des clusters en se basant sur la densité des points. Il peut s'adapter aux grandes quantités de données et n'assume pas que les données soient globulaires. Cependant, ses hyperparamètres qui définissent entre autres la densité doivent être fixés.

### 1.3 Apprentissage machine pour la segmentation d'images satellitaires:

La segmentation d'images pourrait être divisée en quatre classes principales: la segmentation basée sur la région, la segmentation basée sur les bords et la segmentation basée sur les points, ainsi que leur combinaison (Jochen et al.2012). Les régions peuvent être définies en utilisant des critères d'homogénéité basés sur un espace de *features*, qui est dérivé des images satellites multispectrales, permettant ainsi aux régions d'englober plus d'informations que les segments, qui à leur tour profitent des informations spectrales pour transmettre la moyenne, la variance, la médiane, les valeurs minimales et maximales par bandes d'images, et donc, contiennent plus d'informations que les pixels individuels. Les applications géospatiales intègrent des méthodes de segmentation développées pour d'autres domaines tel que la reconnaissance des piétons pour la sécurité routière (Benenson

et al. 2015) ou l'analyse d'images médicales (Bouget et al. 2015). Par conséquent, les modèles basés sur la segmentation des couleurs et des textures et reposant également sur la forme ou le mouvement (Haralick et al. 1973) ont été utilisés dans le traitement d'images satellites. En fait, les distances, le voisinage et les topologies sont essentiels pour les méthodes basées sur les objets. La segmentation des images a évolué avec la disponibilité de bases de données de référence et le développement d'approches d'apprentissage automatique, qui devaient être améliorées. Par conséquent, les méthodes de segmentation étaient basées sur l'ingénierie des fonctionnalités, et de nombreux descripteurs et détecteurs ont été développés tels que les caractéristiques de Haralick [19] qui étaient invariantes au nombre de niveaux de gris, et qui sont calculés en utilisant GLCM (Gray- Level Co-occurrence Matrix), prenant ainsi en compte la texture de l'image. Ils ont été utilisés pour la discrimination des dunes de sable dans la péninsule de Valdes (Blanco et al. 2007). L'histogramme des gradients orientés (HOG) qui est devenu populaire (Dalal et Triggs, 2007) et les modèles binaires locaux (LBP) introduits dans (Ojala et al. 1994) ont servi de descripteurs et ont également été utilisés pour la détection des dunes de sable (Azzaoui et al. 2019). Plus tard, d'autres détecteurs et descripteurs tels que la transformation des caractéristiques invariantes à l'échelle (SIFT) ont été largement utilisés dans différentes applications de vision par ordinateur (Lowe 1999) telles que la détection des piétons, la reconnaissance des empreintes digitales, mais, dans la mesure de nos connaissances, ils n'étaient pas utilisés dans la détection des dunes dans les images satellites. Il convient de noter que d'autres descripteurs importants tels que Speed-Up Robust Features (SURF) (Bay et al. 2008), ont joué un rôle important. En fait, SIFT fonctionne mieux que SURF pour les changements d'échelle, mais SURF a un temps d'exécution inférieur à SIFT lorsqu'il utilisait des images intégrales (Mistry et al. 2017). Fast Retina Keypoint (FREAK) qui a

été introduit par (Alahi et al. 2012) consiste en une série de différences de Gaussiennes (DoG) qui sont composées sur un motif rétinien, a également été utilisé dans de nombreuses applications dans le traitement d'images numérique et la reconnaissance d'objets. On note aussi les fonctionnalités élémentaires indépendantes robustes binaires (BRIEF) qui sont très discriminantes dans le cas de quelques bits (Calonder 2010), et il existe également des points-clés évolutifs invariants robustes binaires (BRISK) (Leutenegger et al. 2011) qui ont un coût de calcul plus faible, ensuite, il y a le FAST Orienté et le BRIEF (ORB) (Rublee et al.2011) qui sont invariants en rotation et résistants au bruit. De plus, les détecteurs MSER (Maximally Stable Extremal Regions) ont été efficaces quand leurs paramètres sont choisis de manière à obtenir plus de stabilité face aux variations d'intensité à différentes échelles (Forssén. 2007). Ces descripteurs étaient des vecteurs qui représentaient des informations, et donc, un simple seuil n'était pas très efficace pour classer des objets et des images complexes. En effet, les vecteurs descripteurs ont été suivis plus tard par l'utilisation d'algorithmes d'apprentissage automatique, qui devaient être utilisés généralement dans le paradigme de l'apprentissage supervisé, où les données étaient divisées en un ensemble d'apprentissage, un ensemble de validation et un ensemble de tests (Abu-Mostafa et al 2012). L'utilisation de techniques de classification ou de régression est généralement basée sur la LR (régression logistique), le SVM (Support Vector Machines), l'ANN Artificial Neural Networks et leurs multiples variations telles que le CNN (Convolutional Neural Networks) qui inclut le DL (Deep Learning). La classification des images de télédétection a également utilisé le champ aléatoire de Markov (MRV) (Li et al. 2014).

# Chapitre 2: La segmentation de texture pour les Barkhanes

## 2.1 Introduction

Les dunes barkhanes sont un type particulier de dunes qui se différencie des autres types par sa forme caractéristique en croissant. Les barkhanes sont toujours observées en groupe. On distingue en effet trois types de formations : Les dunes de sable simples, composées et complexes. Les dunes qui sont spatialement séparées des autres dunes voisines sont considérées comme simples. Lorsque deux ou plusieurs dunes du même type par exemple deux barkhanes fusionnent ou se superposent, elles sont dites composées. Et si les dunes de différents types fusionnent ou se superposent, elles sont dites complexes (McKee, 1979), ou peuvent former des dunes transverses.

Nous considérons dans ce chapitre le cas des dunes barkhanes simples. Ainsi, nous adoptons pour le moment une approche consistant à répartir le problème complexe de détection de dunes barkhanes en sous problèmes plus simples à résoudre. Les solutions ainsi trouvées pourraient être intégrées. Nous commençons par essayer de mieux cerner notre objet d'intérêt : Les barkhanes. Celles-ci sont définies comme étant des dunes mobiles isolées, en forme de croissant, dont les cornes pointent dans le sens du mouvement de ces dunes (Fig.7).




Fig.7 : Illustration d'une dune barkhane

Ces dernières sont formées lorsque l'apport de sédiments est insuffisant pour couvrir tout le substrat, et par conséquent, il n'est pas rare de les retrouver dispersées sur des surfaces rocheuses nues. Les barkhanes possèdent un côté convexe qui fait face au vent, dont la pente est plus douce, et un côté concave sous le vent, dont la pente est plus raide, formée par le glissement du sable. (Elbelrhiti et Hargitai, 2015). Les barkhanes sont aussi retrouvées dans le sable sous-marin, constituant ainsi des formations subaquatiques (Hersen, 2005). Les barkhanes ont aussi été découvertes dans d'autres planètes, et sont donc partie d'un phénomène extra-terrestre.

En effet, des dunes barkhanes ont été trouvées sur Mars, Vénus et Titan (Bourke et al., 2008). Leur étude est d'autant plus importante car non seulement elle a un impact immédiat sur les populations locales des régions arides, dans le contexte de veille associée aux risques naturels, mais aussi, la compréhension de ce phénomène permet aussi de contribuer à l'exploration spatiale. Comme illustration de cela, l'orientation des barkhanes trouvés sur Mars a été utilisée pour déduire les régimes de vent près de la surface (Bourke et al., 2008). Alors que les dunes de sable actives refléteraient les vents dominants actuels, les dunes de sable dormantes faisaient office d'archive qui aurait conservé des informations concernant les régimes de vent plus anciens qui sont maintenant disparus (Fenton 2006). Nous explorons dans ce chapitre le cas d'images satellitaires à

très haute résolution (MRO) représentant un groupe de dunes barkhanes simples sur Mars. L'intérêt est d'étudier un cas relativement simple, mais néanmoins très instructif.

## 2.2 Les méthodologies de segmentation de dunes barkhanes

### 2.2.1 Imagerie satellitaire et dunes de sable:

Les chercheurs ont utilisé des images satellitaires pour étudier les dunes de sable et collecter des données plus efficacement dans des environnements difficiles: dans les premières tentatives (Fryberger et Dyne 1979) ont obtenu de bons résultats qui leurs permettaient d'étudier la naissance des dunes. (McKee 1979) a aussi utilisé la télédétection pour cartographier manuellement les dunes de sable et développer leur taxonomie, plus tard (Blumberg 1998) a commencé la détection de dunes de sable à l'aide de leur réflectance de surface. Dans (Vermeesch et Drake, 2008), des paires d'images satellites ASTER ont été combinées pour extraire des barkhanes et étudier leur dynamique. Dans (Bishop, 2010), des coques convexes ont été utilisées pour combiner le modèle d'élévation numérique SRTM et Landsat TM orthorectifié, puis un indice statistique R pour estimer le degré d'auto-organisation des dunes dans la mer de sable d'Ar Rub 'al Khali dans la péninsule arabique. Dans (Wolfe et al, 2009), Le LiDAR a été combiné avec la résolution spectrale et spatiale des images satellites QuickBird, et la luminescence par stimulation optique a été utilisée pour créer un modèle d'élévation des dunes barkhanes canadiennes. Dans (Sheidt et al. 2010), la composition minérale du champ de dunes de Gran Desierto, au Nouveau-Mexique, aux États-Unis, a été cartographiée à l'aide d'indices de rapport sur des images ASTER (radiomètre spatial d'émission et de réflexion spatiales avancées). (Adnani et al. 2019, Adnani et al. 2020) a aussi utilisé des indices pour détecter la composition minérale des dunes sur des images satellitaires IKONOS. En général, les zones reculées pour lesquelles l'accès est parfois impossible ont bénéficié de l'utilisation de la télédétection ainsi que des avancées des algorithmes de vision par ordinateur et d'apprentissage automatique. En effet, la

disponibilité des images Landsat, MODIS, IKONOS, HIRISE et MRO entre autres a permis non seulement d'étudier les dunes dans les zones d'accès difficiles telles que le Désert du Namib et désert du Sahara mais aussi pour découvrir l'existence de dunes de sable barkhanes dans d'autres systèmes planétaires tels que Mars: en (Hansen et al. 2011) des images de MRO (Mars Reconnaissance Orbiter) ont été utilisées pour étudier les modifications saisonnières des dunes polaires du nord de Mars grâce à rapport signal / bruit (SNR) dans les images des dunes sombres. Des dunes ont également été trouvées dans Vénus: dans (Bourke et al.2008), des images radar Cassini ont été utilisées et des dunes noires contrastées pour estimer leurs propriétés.

### 2.2.2 L'imagerie satellitaire à très haute résolution MRO:

Nous explorons dans ce chapitre l'imagerie satellitaire de très haute résolution que nous avons utilisée dans la détection de dunes barkhanes présentes sur Mars. Elle a été prise par l'instrument HiRISE (High Resolution Imaging Science Experiment) qui est monté sur le satellite MRO (Mars Reconnaissance Orbiter). L'image «ESP\_034815\_2035» est fournie par la NASA / JPL / University of Arizona. Elle contient une formation de barkhanes composée de 60 dunes. Cette formation est située dans un cratère près de Mawrth Vallis, Oxia Palus Quadrangle, et qui a été présenté comme un site d'atterrissage possible pour Mars 2020 (Loizeau et al. 2015).

Les dunes martiennes ont une échelle bien supérieure à celle des dunes terrestres entre autres à cause des pressions atmosphériques différentes (Claudin et Andreotti 2006), qui font une étude comparative entre les dunes terrestres, martiennes et subaquatiques. Une petite dune de Mars fait ainsi environ 650 m de long, alors qu'une petite dune fait environ 20 m de long. Le tableau suivant contient les détails de l'image de Mars utilisée (Tab.1).

Coordonnées	Maximum latitude = 23.292862° Minimum latitude = 23.088633° Eastern Most longitude = 339.650653° Western Most longitude = 339.529501°
Résolution spatiale	0.25 meters/pixel
Date	December 30th, 2013
Superficie	32.38 km <sup>2</sup>

Tab 1. Informations sur les caractéristiques de l'image MRO

Bien que la qualité de l'image soit excellente, il est nécessaire de l'améliorer afin de l'adapter à l'application en cours. Nous présentons ici des méthodes que nous avons utilisées. La première étant l'ajustement du contraste de l'image, de sorte à ce que 1% des pixels soient saturés à des intensités faibles et élevées. Aussi, les images satellitaires sont très exposées au bruit, et donc l'utilisation de filtres adaptatifs 2D est très utiles pour permettre l'élimination du bruit. Leur combinaison est d'autant plus efficace. Le premier filtre utilisé était le filtre médian avec une fenêtre 3x3 qui est un filtre non linéaire permettant de mieux conserver les contours. Le deuxième filtre appliqué que l'on présente ici un filtre statistique appelé filtre de Wiener qui se base sur les estimations de la moyenne et de la variance d'un voisinage local de chaque pixel d'ancrage.

### 2.2.3 Les descripteurs de texture de Haralick:

Les descripteurs de texture de Haralick sont multiples et nous en citons : l'autocorrélation, le contraste, la corrélation, la proéminence du cluster, l'ombre du cluster, la dissimilarité, l'énergie, l'entropie, l'homogénéité, la probabilité maximale, la variance de la

somme des carrés, la moyenne de la somme, la variance de la somme, l'entropie de la somme, la variance de la différence, la différence entropie, information mesure de corrélation, différence inverse normalisée et moment de différence inverse normalisé (Soh, 1999; Haralick, 1973; Clausi 2002). Il s'agit en effet d'une énumération de descripteurs qui reposent sur la matrice GLCM (Grey-Level Co-occurrence Matrix) qui elle-même utilise des patchs d'images qui sont réduits à 16 niveaux de gris, pour conserver un nombre car cette méthode est très gourmande en calcul. La matrice GLCM a été extraite dans les 4 directions (0 °, 45 °, 90 ° et 135 °). Ces descripteurs ne sont pas tous utiles, et une sélection s'impose pour n'en utiliser que ceux qui permettent d'extraire une information pertinente pour notre application. Cette sélection peut se faire en utilisant des tests statistiques comme le test de Kolmogorov - Smirnov que nous présentons dans ce qui suit :

#### 2.2.4 Le test de Kolmogorov - Smirnov:

Afin de classifier les échantillons d'image, on en sélectionne un ensemble qui sera étiqueté comme positif ou négatif. Le test de Kolmogorov - Smirnov à deux échantillons est ensuite utilisé pour mesurer la distance entre les distributions de probabilité des classes positives et négatives relatives à chaque descripteur de Haralick. Les descripteurs Haralick obtenant les distances maximales sont ensuite choisis comme paramètres pour classer les échantillons positifs et négatifs. L'avantage de cette approche est sa vitesse d'exécution qui compense le temps d'exécution de l'extraction des descripteurs sur l'image satellitaire. Le seuil de séparation entre échantillon positif et négatif peut être calculé pour chaque descripteur choisi en utilisant la statistique J de Youden.

En effet, celle-ci permet de trouver le point de coupure optimal qui maximise la distance entre la courbe de fonctionnement du récepteur, ou Receiver Operating Curve (ROC) et la ligne de niveau de chance qui correspond à l'axe  $FPR = TPR$ , False Positive Rate

= True Positive Rate, où le taux de faux positif est égal au taux de vrais positifs. Un signe binaire doit également être calculé et enregistré. Lorsque ce signe était égal à 1, cela signifiait que les positifs étaient supérieurs à la valeur seuil, et quand il était égal à - 1, cela signifiait que les positifs étaient inférieurs à la valeur seuil. Ceci permet en fin de compte de disposer d'une segmentation de texture basée sur une décision statistique. Mais il reste à confirmer si les zones négatives dont la texture ne correspond pas à celle du sol Martien caractérisé par ses cratères, correspond bien à des dunes de sable barkhanes. Pour cela l'utilisation de descripteurs supplémentaires pour affiner les résultats est nécessaire.

#### 2.2.5 Les descripteurs de SURF et MSER pour les barkhanes:

Le descripteur SURF (Speed Up Robust Features) (Leibe et al.2008) est utilisé conjointement comme détecteur et descripteur d'image. Invariant à l'échelle et à l'orientation, il est une variante plus rapide du descripteur SIFT (Scale-Invariant Feature Transform). Le descripteur MSER (Maximally Stable Extremal Regions) (Matas et al. 2002) quant à lui permet d'extraire des blobs correspondant à des régions covariantes. Les dunes barkhanes ont une texture particulière qui peut être exploitée en faisant appel à une combinaison des descripteurs MSER et SURF. En effet, MSER permet d'extraire des régions et se complète avec SURF qui extrait des points d'intérêt.

Dans la détection des dunes barkhanes, Le SURF-128 a été privilégié à la place du SURF-64 afin d'améliorer la précision des résultats. Au stade de l'entraînement, les points d'intérêt sont étiquetés comme positifs ou négatifs selon s'ils se trouvent à proximité des dunes barkhanes ou pas. Les points SURF doivent être sélectionnés avec un seuil de caractéristique suffisamment élevé (supérieur à 30) pour garantir que qu'un nombre conséquent de points positifs a été détecté et ainsi limiter les faux positifs.

En fait, les points négatifs SURF étaient beaucoup plus nombreux que les points positifs, en raison des positions clairsemées des dunes barkhanes, il faut choisir une tactique pour équilibrer l'ensemble d'entraînement. Pour cela, la sélection d'un nombre égal de points SURF positifs et négatifs, avec bien sûr, une sélection aléatoire des points SURF négatifs est nécessaire pour limiter le biais. Il est aussi possible de grouper les points SURF négatifs à l'aide de l'algorithme de K-Means, avec K choisi comme égal au nombre de points positifs, cependant cela augmente le temps d'exécution.

Le détecteur MSER des régions extrêmes à stabilité maximale peut être utilisé pour détecter les régions ayant un aspect de tâche. Ses paramètres doivent être ajustés sur des échantillons d'apprentissage. Par exemple, dans le cas des barkhanes, la variation de surface maximale entre les régions extrêmes à différents seuils d'intensité dans les images MRO correspond à 30%.

Ces éléments étant définis, il reste à les lier ensemble en développant un algorithme qui puisse combiner ces descripteurs pour prendre une décision permettant de classer l'objet segmenté en dune ou pas.

### 2.3 Approche proposée pour la fusion des descripteurs de segmentation des barkhanes

Nous avons introduit un nouvel algorithme permettant à partir de descripteurs SURF et MSER, de prendre une décision sur la classe de l'objet segmenté, présenté dans (Alg.1) :

L'algorithme consiste à vérifier pour chaque région MSER, l'ensemble des points SURF qu'elle contient. Elle commence par les compter, puis évalue le ratio des points positifs, et si ce dernier est

majoritaire, elle est listée comme région segmentée correspondant à une dune barkhane.

```
For Each MSER region
  score ← 0
  region_surf_counter ← 0
  region_positive_surf_counter ← 0
  For Each SURF point
    If SURF point inside MSER region
      INCREMENT region_surf_counter
      If model.predict(SURF) == 1
        INCREMENT region_positive_surf_counter
      End
    End
    score ← region_positive_surf_counter / region_surf_counter
    If score > 50%
      BB ← min_Bounding_Box(MSER region)
      List_candidates.add(BB)
    End
  End
End
```

#### Alg.1 Pseudo algorithme pour la fusion de descripteurs

Par la suite, les régions correspondant à des barkhanes sont englobées dans des cadres de limitation minimaux (Bounding Box), basées sur l'algorithme Convex Hull. Nous fusionnons ces candidats lorsque le seuil de superposition dépasse 30%.

### 2.4 Résultats expérimentaux

Les caractéristiques Haralick retenues parmi toutes les autres sont respectivement la proéminence et la corrélation des clusters. Les histogrammes suivants ont montré la distribution des échantillons positifs et négatifs pour les 128 et 64 caractéristiques sélectionnées dans Fig.8.




Fig. 8 : La classification par proéminence: La ligne verte (indice de Youden) séparant les échantillons (A gauche 128x128, à droite : 64x64)

Deux échelles de tailles de fenêtres coulissantes ont été considérées: 128x128 ainsi que 64x64. Nous avons évalué l'impact de ces deux échelles sur la précision des résultats et sur le temps d'exécution. Le tableau suivant (Tab.3) affiche les résultats.

SU RF-128	Erreur K-Fold (K= 10)	Temps execution apprentissage (s)	Temps execution test (s)
128x128	0.0602	27.232531	1.468286
64x64	0.0919	19.767895	0.958666

Tab.2 : Résultats de la segmentation et temps d'exécution

La fenêtre coulissante 64x64 a donné un meilleur temps d'exécution que la fenêtre 128x128, avec une différence de 27%, mais l'erreur de mesurée par validation croisée a révélé que l'échelle d'échantillons 128x128 a donné un résultat supérieur de 33% par rapport au résultat obtenu par l'échelle d'échantillons 64x64. Donc, plus on augmente l'échelle et plus diminue l'erreur, et plus diminue l'échelle, plus on gagne en temps d'exécution. Il est à noter que les deux échelles ont permis de détecter avec succès toutes les 60 dunes de barkhanes de l'image MRO, dans l'ensemble, la méthode était satisfaisante en termes de temps de traitement et de précision. La Fig.9 suivante illustre les résultats obtenus à chaque étape allant de 1 à 6, avec une variation de la taille de fenêtre à 128x128 et 64x64 respectivement dans les étapes 3a, 4a et 3b, 4b.

<b>Clé de lecture de la figure 9</b>	
1 : Image d'origine	2 : Image améliorée
3a : Segmentation 128x128	3b : Segmentation 64x64
4a : Prédiction SURF 128x128	4b : Prédiction SURF 64x64
5 : Résultats MSER	6 : Fusion finale des candidats




Fig.9 : Illustration des résultats de la segmentation à chaque étape du traitement où chaque image correspond à la clé indiquée précédemment

## 2.5 Conclusion

Nous avons présenté dans ce chapitre une approche initiale qui sépare le problème de segmentation en deux parties : La première a consisté à éliminer les surfaces de terrain vide par une segmentation par texture. Nous avons réalisé cela par la sélection d'un sous ensemble de descripteurs de Haralick en se basant sur le test statistique de Kolmogorov-Smirnov. La seconde partie a consisté à segmenter les régions correspondant aux dunes barkhanes. Nous avons réalisé cela en introduisant un algorithme qui fusionne les descripteurs MSER et SURF. Cette approche donne de très bons résultats dans l'image MRO, mais reste limitée pour les images IKONOS où la texture est insuffisante pour segmenter les dunes. Nous introduisons pour cela une nouvelle approche dans le chapitre suivant.

# Chapitre 3: Un processus complet pour la segmentation des contours des dunes Barkhanes

## 3.1 Introduction

L'utilisation de l'imagerie satellite ainsi que de la vision par ordinateur et les algorithmes d'apprentissage machine est essentielle pour effectuer des traitements avancés sur les images permettant d'interpréter leur contenu de dégager des informations pertinentes au regard de l'application voulue. Dans le cas des dunes de sables barkhanes, la collecte de données sur les dunes de sable qui sont généralement dispersées à la surface de grands déserts est difficile. Il s'agit d'autant plus d'une tâche exigeante à cause du mouvement permanent des dunes qui forment des couloirs composés parfois de milliers de barkhanes étendues sur plusieurs centaines de kilomètres, rendant toute étude régulière sur le terrain un défi pénible et onéreux. En effet, les chercheurs ont utilisé des images de télédétection pour étudier les dunes de sable et collecter des données plus efficacement dans ce type d'environnements rudes. Les premières remontent à la fin des années 70s (McKee et al.1979) où la télédétection a été utilisée pour cartographier manuellement les dunes de sable et développer leur taxonomie, plus tard, avec le développement de la télédétection, plusieurs approches se sont développées mais qui n'ont été appliqués que partiellement à la segmentation des dunes barkhanes qui est restée en grande partie manuelle et donc fastidieuse. Nous proposons dans ce chapitre une approche qui introduit un processus de bout en bout, commençant à partir d'images satellitaires à haute résolution, en passant par

l'amélioration d'image, la détection des dunes, la segmentation de leur contours, et aboutit à la génération automatique de données d'allométrie. Nous expliquons dans ce qui suit en détail les étapes.

## 3.2 Les méthodes de détection, segmentation et allométrie des barkhanes:

### 3.2.1 Préparation de l'image satellitaire à haute résolution IKONOS:

Les images satellitaires IKONOS sont composées de 5 bandes. L'image haute résolution a été prise par le satellite IKONOS le 23 juillet 2003, au sud du Maroc, près de la ville de Tarfaya, dans le désert du Sahara, avec des coordonnées comprises entre  $27^{\circ} 26'8.6621''$  N,  $13^{\circ} 08'5.2628''$  W et  $27^{\circ} 41'1.0350''$  N,  $13^{\circ} 22'07.20''$  W. Nous considérons dans ce chapitre la bande panchromatique, qui correspond à une résolution spatiale de 0.82m/pixel. La superficie réelle représentée par l'image correspond approximativement à 13 Km<sup>2</sup>. Nous améliorons l'image en combinant l'égalisation d'histogramme, puis successivement le filtre de Weiner et le filtre médian, afin de réduire le bruit.

### 3.2.2 La détection des barkhanes par cascade hiérarchique de classificateurs :

La texture des dunes barkhanes se confond parfois avec les surfaces environnantes couvertes de sable. Cependant, leur forme caractéristique 3D semblable à un croissant, crée avec les réflexions du soleil, une ombre portée particulière, qui peut être exploitée pour les détecter de manière fiable. Les cascades hiérarchiques de classificateurs avec les ondelettes de Haar (Viola et Jones, 2001; Liao

et al., 2007) sont particulièrement adaptées à cette situation. Le classificateur en cascade utilisé est basé sur un ensemble de classificateurs faibles boostés pour produire un vote à chaque étape de la hiérarchie. Individuellement, un classificateur faible est à peine meilleur qu'un tirage au sort, mais lorsqu'il est Boosté, il constitue un modèle fiable pour la prise de décision. Il sélectionne les meilleurs classificateurs faibles en les pondérant selon leur erreur (Eq.3.1) avec les coefficients à l'itération  $t$  et  $h(x)$  l'hypothèse du vecteur  $x$ :

$$(Eq.3.1) \quad h(x) = \begin{cases} 1 & \sum_{t=1}^T \alpha_t h_t(x) \geq \frac{1}{2} \sum_{t=1}^T \alpha_t \\ 0 & \text{otherwise} \end{cases}$$

Puisqu'il s'agit d'une méthode d'apprentissage machine, il faudra donc commencer par diviser l'image satellitaire à haute résolution de manière aléatoire en deux parties: la première partie, qui représente environ 70% de la superficie totale, est utilisée pour l'entraînement, et la superficie restante, 30% de l'image, sera été mise de côté pour tester et évaluer l'apprentissage. Il faudra en effet réaliser une annotation manuelle d'un ensemble limité de dunes afin d'avoir une vérité terrain de référence. L'entraînement des classificateurs permet de fixer les paramètres du modèle de sorte à reconnaître les dunes barkhanes. Le résultat devra être évalué sur la région qui a été réservée à cet effet. Cette approche produisant de nombreux candidats superposés, il faudra ajouter une étape de traitement supplémentaire qui est la fusion de candidats, afin de combiner les encadrements (Bounding Boxes) qui se chevauchent. Le résultat de cette première étape est donc un ensemble d'images contenant les dunes de sable barkhanes détectées.

### 3.2.3 La segmentation des contours des barkhanes par un modèle de forme actif :

Les dunes barkhanes sont des objets qui apparaissent dans les images sous forme de croissant, formé par 3 courbes caractéristiques : La courbe de crête, la courbe sous le vent, et la courbe face au vent (Brink, Leeward, Windward). Les contours peuvent être segmentés en utilisant un modèle de forme actif ASM (Active shape Model) à 3 courbes, correspondant aux 3 contours caractéristiques des dunes barkhanes. L'ASM est constituée de 3 étapes, on commence par l'alignement des formes qui consiste à former un pour segmenter les contours des dunes barkhanes. Chaque dune est identifiée par 30 points de repère et chaque 10 points de repère correspondent à un contour. Comme les dunes barkhanes ont des échelles et des tailles différentes, il est nécessaire de normaliser leurs formes. Par conséquent, nous utilisons une analyse de Procrustes, qui est définie par un algorithme dont le but est de minimiser la distance de chaque forme par rapport à la moyenne de toutes les formes. Il en résulte une minimisation des différences d'échelle, de rotation et de translation entre les formes, en utilisant entre autres la transformation suivante (Eq.3.2)

$$T_{X_t, Y_t, s, \theta} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} X_t \\ Y_t \end{pmatrix} + \begin{pmatrix} s \cos \theta & -s \sin \theta \\ s \sin \theta & s \cos \theta \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} \text{ Eq.3.2}$$

Avec et les coordonnées avant la transformation et  $T(x,y)$  les coordonnées après la transformation. L'étape suivante est la réduction de dimensionnalité. En effet, puisque le modèle contient 30 points de repère, chaque dune est représentée comme un vecteur à 30 dimensions. Nous utilisons l'ACP (analyse en composantes

principales) pour réduire le nombre de paramètres contrôlant la forme d'une dune barkhane. Le modèle réduit a été utilisé par la suite pour limiter la variation des formes des barkhanes. L'étape suivante consiste à extraire le profil de la dune, pour pouvoir par la suite le retrouver lors de la correspondance de contour. Cette étape consiste à apprendre donc les caractéristiques du voisinage du contour. La méthode classique utilise une approche statistique. Elle consiste pour chacun des 30 points de repère, à tracer une ligne normale, perpendiculairement au contour correspondant de la dune barchans. Ensuite, à partir de ce profil, des dérivées d'intensité ont été calculées. La combinaison de ces profils d'intensité permet de générer un modèle de distribution gaussien multivarié. Nous avons modifié cette dernière partie et introduit une variation nouvelle, qui augmente la robustesse de la mise en correspondance des contours. Nous l'exposons dans la section suivante des améliorations apportées, dans ce même chapitre. Le mapping de contour dans la méthode classique se fait en utilisant la distance de Mahalanobis. Le modèle d'ACP sert dans cette étape à limiter les formes acceptables du modèle après spécification de la variance tolérée par rapport à la forme moyenne.

#### 3.2.4 Les mesures d'allométrie des barkhanes :

On ne retrouve pas dans la littérature une mesure normalisée de l'allométrie des barkhanes. En effet, les géologues travaillant généralement manuellement sur le sujet, utilisent des approches

individuelles. Nous introduisons un nouveau modèle normalisé que nous illustrons dans la (Fig.10) et qui va permettre à partir de contours segmentés de calculer immédiatement les mesures d'allométrie des barkhanes.




Fig.10 : Modèle d'allométrie des dunes barkhanes

$w, L, \theta, h1, h2, ih, S$  correspondent respectivement à la largeur (Width), longueur (Length), angle d'inclinaison ( $\theta$ ), Largeur des cornes (Horn widths), distance entre cornes (Inter-horns distance), et empreinte au sol (Surface area). Les correspondent au différents centroides : pour la courbe face au vent (Windward), pour la crête, pour la courbe sous le vent (Leeward). NS représente un axe Nord- Sud hypothétique.

Ainsi, nous réduisons une dune à un vecteur multidimensionnel (Eq.3.4).

$$V(d)=(w,L,\theta,h1,h2,ih,S) \quad (\text{Eq.3.4})$$

Nous allons pouvoir ainsi comparer plusieurs dunes barkhanes et explorer les corrélations entre leurs différents attributs.

### 3.3 Approche proposée pour une intégration de la détection, segmentation et allométrie des barkhanes

Nous avons mis en place processus de bout en bout permettant à partir d'images satellites à haute résolution, réaliser une analyse complète permettant de récupérer en sortie les données d'allométrie des Barkhanes. Le processus que nous avons introduit est illustré dans le schéma suivant (Fig 11) où chaque couloir représente une étape majeure : Le premier consiste à détecter les positions des dunes et à les encadrer, le second couloir consiste à segmenter les contours des dunes et le dernier couloir est relatif au calcul de l'allométrie.

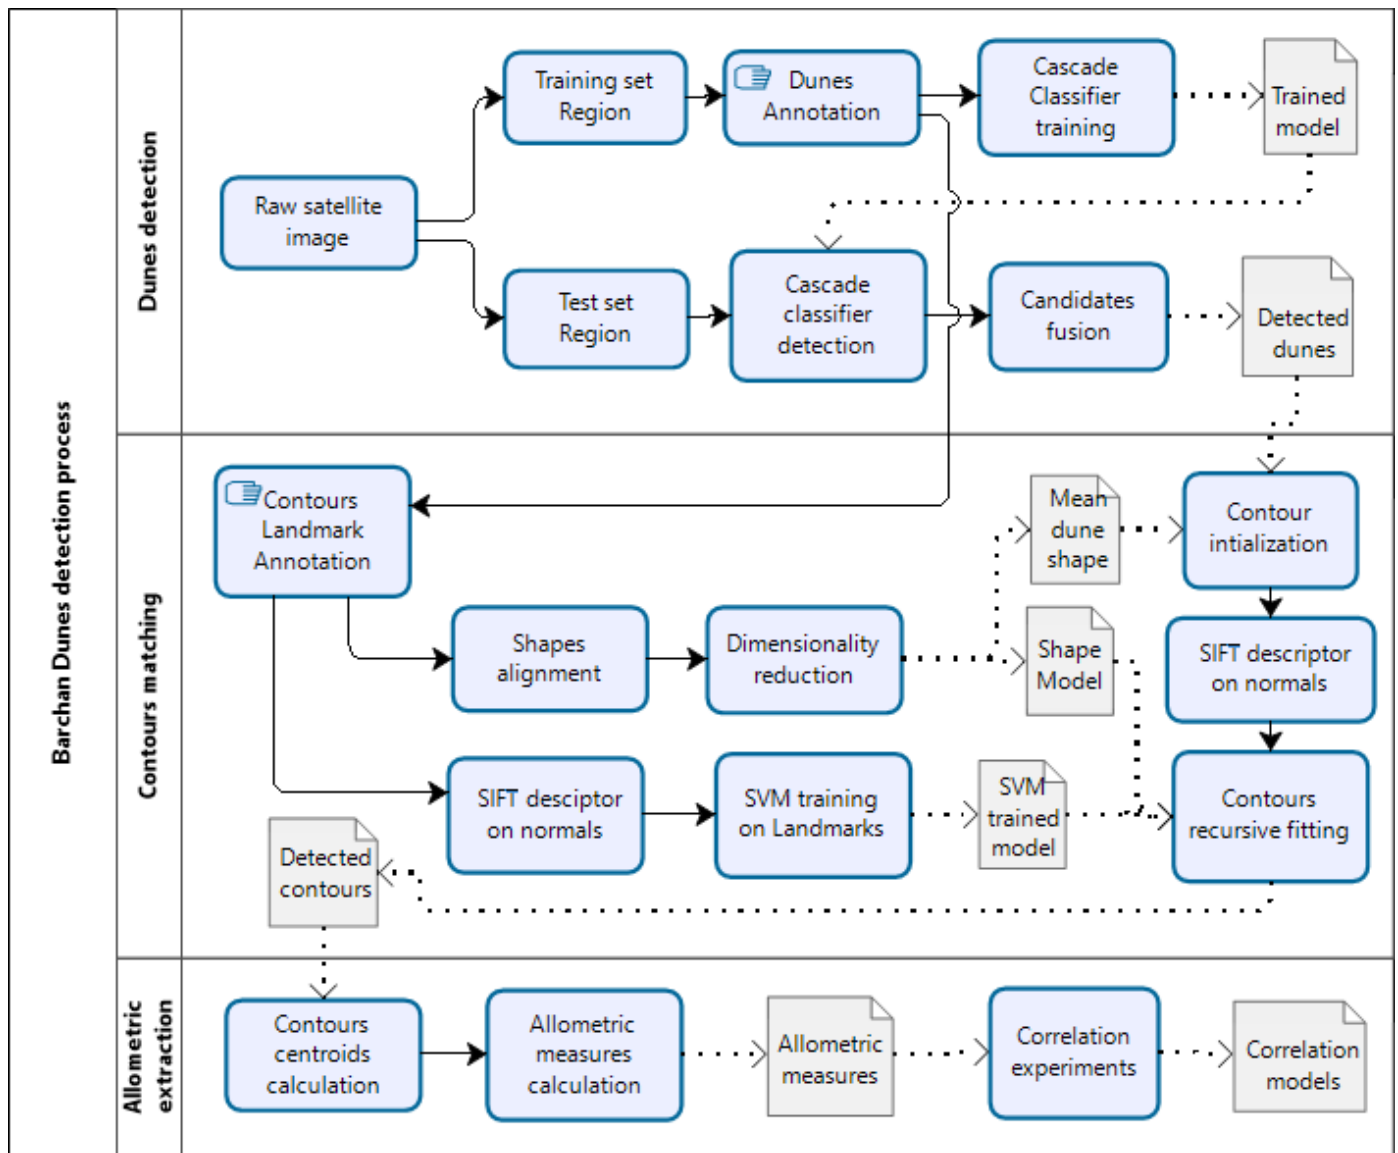


Fig 11 : Processus complet de détection, segmentation et allométrie des barkhanes


Les deux premiers couloirs font appel aux méthodes d'apprentissage machine. Pour la seconde étape de mise en correspondance des contours des dunes, nous avons introduit une nouvelle variation sur le modèle ASM classique. En effet, afin d'améliorer sa robustesse, nous avons remplacé la dernière étape consistant à utiliser un modèle multi Gaussien et la distance de Mahalanobis, par un modèle basé sur l'extraction des points d'intérêt SIFT et leur évaluation en utilisant une machine à vecteur de support SVM (Support Vector Machine) qui maximise l'hyperplan de séparation décrit dans

(Eq.3.5). Avec  $\alpha^*k$  les multiplicateurs optimaux de Lagrange, les labels et  $K( )$  est le noyau (Kernel) appliqué à l'ensemble de données d'apprentissage de taille  $p$ .


$$h(x) = \sum_{k=1}^p \alpha_k^* l_k K(x_k, x) + w_0 \quad (\text{Eq.3.5})$$

### 3.4 Résultats obtenus

Notre approche a été appliquée sur l'image satellitaire IKONOS présentée précédemment. Nous allons présenter les résultats de chaque étape. Notre base de données consistait en 240 images avec 120 dunes de sable que nous avons réparties en 80 dunes pour l'apprentissage et 40 pour le test, plus 120 images qui ne contiennent aucune dune, principalement du terrain vide qui entoure les dunes. Un exemple de la base de données est représenté dans la (Fig 12) qui montre les échantillons positifs et négatifs.



(a)



(b)

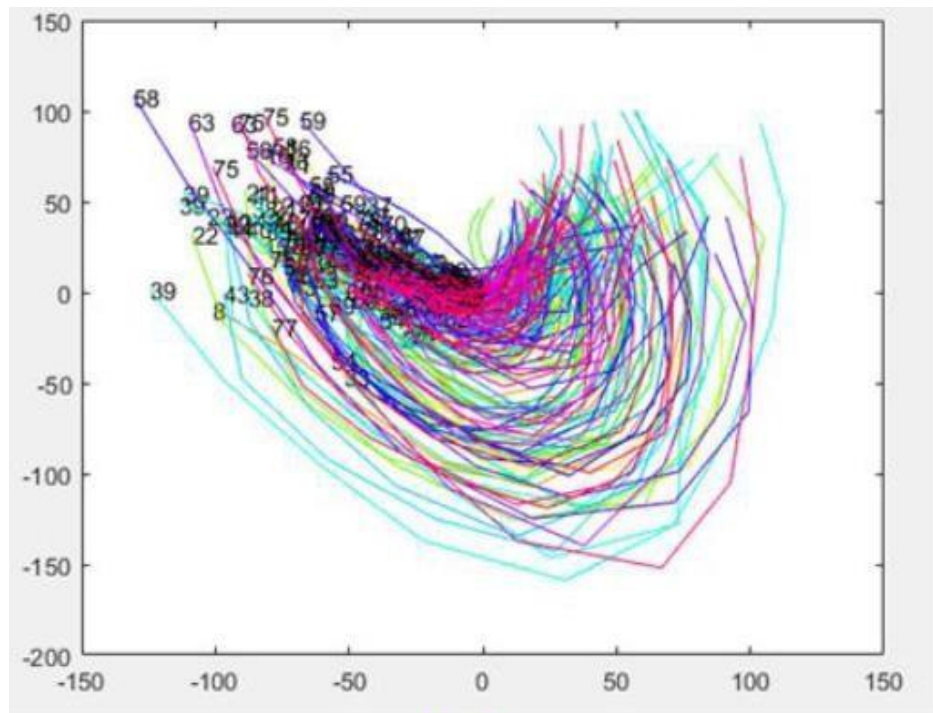
Fig 12 Echantillon de la base de données des images d'apprentissage  
a : Dunes barkhanes  
b : Terrain vide

La matrice de confusion suivante présente les résultats d'évaluation de la première étape avant et après fusion des résultats (Tab.3). En effet, nous avons constaté que la précision de détection des dunes est passée de 65% à 77,5%. Cette augmentation s'explique par le fait que la détection des chevauchements a tendance à créer des faux positifs, qui correspondaient généralement à des parties des dunes telles que des cornes. La fusion réduisait le nombre de faux négatifs, améliorant ainsi la précision.

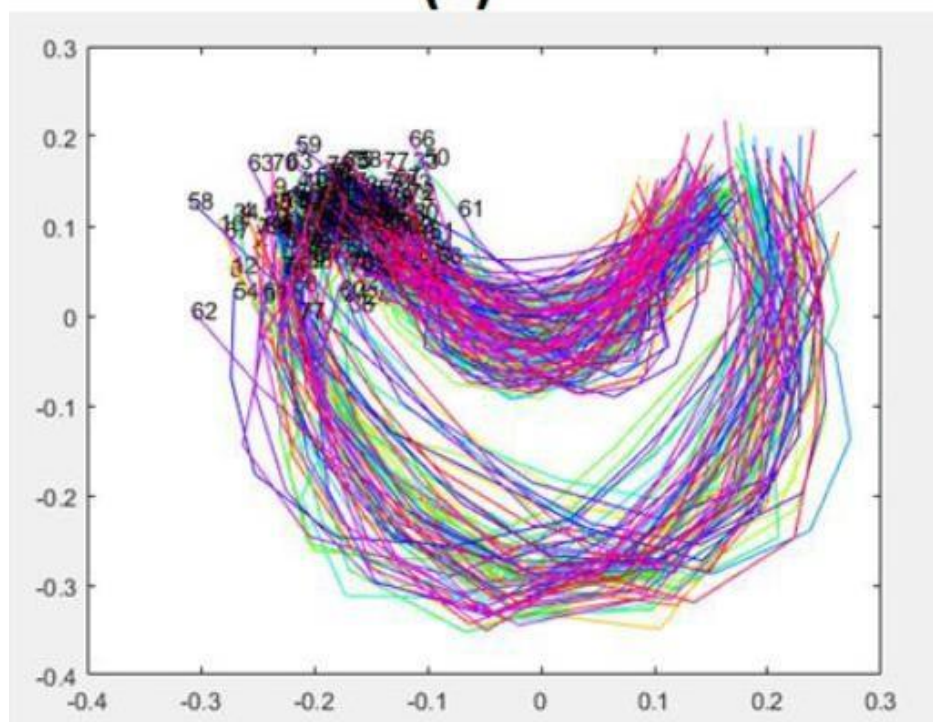
Détection des barkhanes		Vérité terrain	
		Positif	Négatif
Prédiction (avant fusion des candidats)	Positif	18	23
	Négatif	5	34
Prédiction (après fusion des candidats)	Positif	29	12
	Négatif	6	33

Tab 3 : Matrice de confusion de la détection des barkhanes

Pour la deuxième partie de segmentation l'approche ASM que nous avons améliorée commence par l'alignement des contours par Procrustes. La figure suivante montre l'alignement des contours d'apprentissage (Fig.13).



**(a)**



**(b)**

Fig 13 Alignement des contours par analyse de Procrustes

a : Contours de barchanes avant alignement

b : Contours de barchanes après alignement

Il s'agissait par la suite de réduire la dimensionnalité en utilisant une ACP (Analyse en Composantes Principales) que nous avons réalisé et avons réduit le vecteur représentant le contour des barkhanes de 30 à 8 dimensions. En effet, nous nous sommes arrêtés à 90% de pourcentage expliqué. (Tab 4)

	Valeurs propres	Pourcentage expliqué
1	0.01455	32.56%
2	0.0088493	52.36%
3	0.0049935	63.54%
4	0.0038906	72.25%
5	0.0031457	79.29%
6	0.0018443	83.41%
7	0.0016682	87.15%
8	0.0012165	89.87%

Tab 4 : Résultats de l'ACP des contours des dunes

La figure suivante illustre deux modes de variation du contour des barkhanes (Fig.14). Nous avons choisi de limiter la variation des formes par un facteur de  $2\lambda$ .

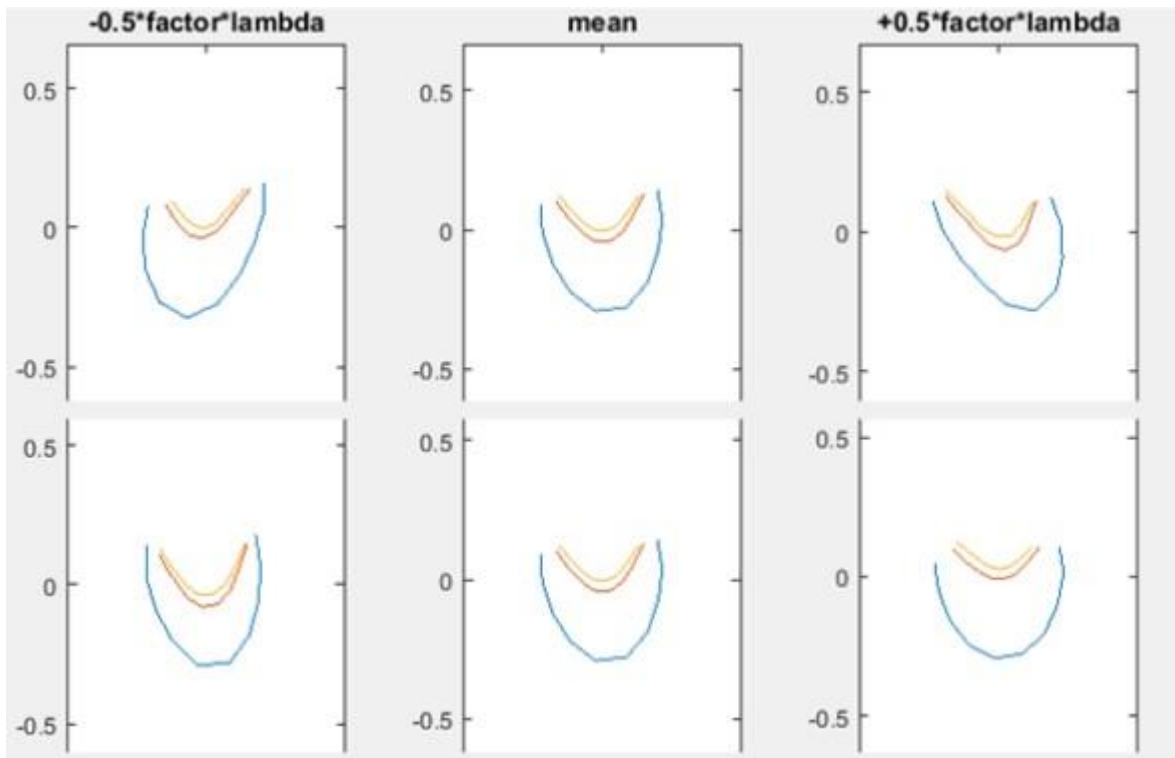


Fig.14 : Exemple de 2 modes différents de barkhanes

Dans la colonne centrale la moyenne

Dans les 2 colonnes adjacentes les limites de variances

L'étape de correspondance des formes avec les contours des dunes barkhanes repose sur une approche itérative où la première itération correspond à la dune moyenne, dont la forme s'ajuste progressivement pour se mettre en correspondance avec le contour des dunes barkhanes. La (Fig.15) illustre un exemple.




Fig.15 : Convergence de la mise en correspondance de contour

A gauche : Les points d'ancrage en bleu, et les normales selon lesquelles elles se déplacent pour converger.

A droite : Les différentes itérations représentant la convergence vers le contour de la dune.

Nous résumons dans la figure suivante (Fig.16) le processus complet que nous avons développé depuis l'image satellitaire brute jusqu'à la segmentation et l'allométrie.




Fig.16 : Le processus de détection, segmentation de contours et de calcul de l'allométrie des dunes barchanes.

1. L'image satellite après amélioration du contraste et réduction du bruit
2. L'image satellite après détection des dunes à l'aide du classificateur hiérarchique
3. Une partie agrandie de l'image satellite en 2
4. Les dunes après normalisation du ROI à 128x128 pixels

5. Les lignes rouges sont des normales le long desquelles les descripteurs SIFT ont été calculés. Les points bleus représentent le SIFT classé comme positif à l'aide de SVM, formant la nouvelle itération des contours représentée en bleu
6. Les contours des dunes résultants sont en blanc, les caractéristiques des dunes mesurées par notre algorithme sont les segments jaunes, le résultat final est un vecteur (largeur, longueur, largeurs des cornes)

Enfin, nous présentons les résultats de corrélation statistique entre les différentes mesures d'allométrie des dunes où l'on observe les corrélations dans les (Fig 17, Fig 18, Fig 19, Fig 20).

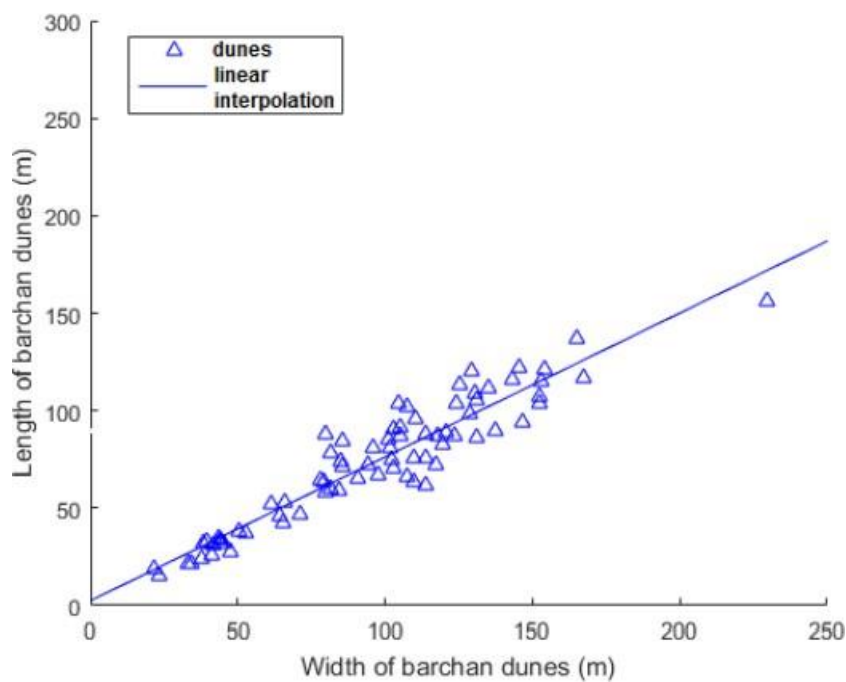


Fig.17 : Exemple de corrélation entre les mesures d'allométrie des dunes :  $f(w) = L$

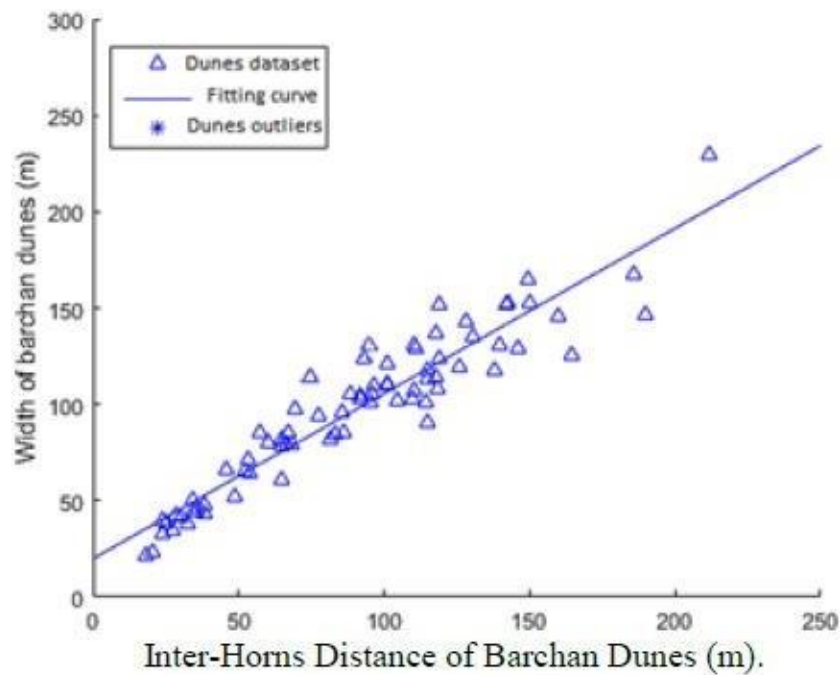


Fig.18 : Exemple de corrélation entre les mesures d'allométrie des dunes :  $f(ih) = w$

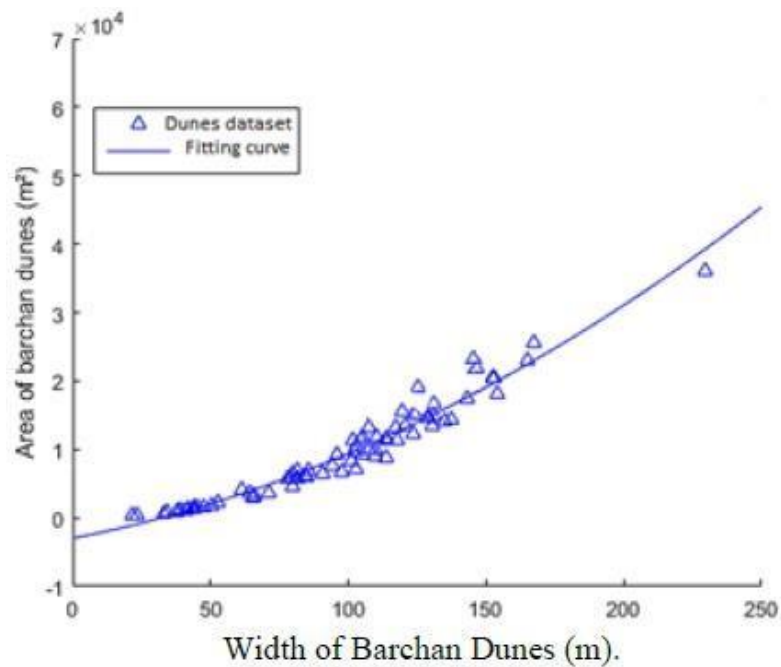


Fig.19 : Exemple de corrélation entre les mesures d'allométrie des dunes :  $f(w)=S$

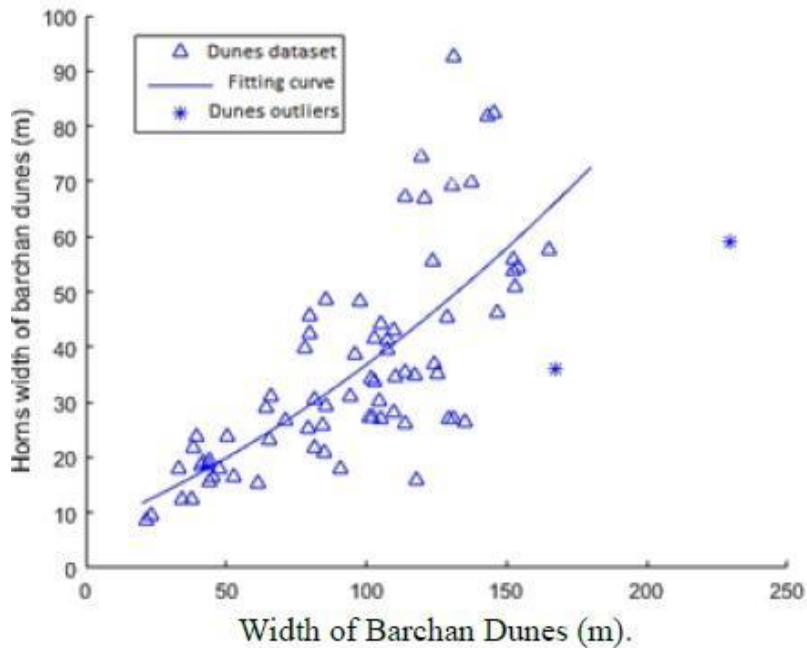


Fig.20 : Exemple de corrélation entre les mesures d'allométrie des dunes :  $f(w) = h_1 + h_2$

Nous avons trouvé des résultats similaires dans (Elbelrhiti et al. 2005), dans lequel il a été constaté sur le terrain, dans les régions de Laayoune et dans la région de La Joya, qu'il existe une relation de premier ordre entre la largeur de la dune notée  $W$  et la somme des largeurs des cornes notée  $\Delta$  (Eq.3.6)

$$\Delta \propto W \text{ avec } \Delta = \Delta_l + \Delta_r \quad (\text{Eq.3.6})$$

Par la suite, une figure en particulier a attiré notre attention et qui correspond à la taille de la dune en termes de superficie occupée en fonction de sa direction par rapport à l'axe Nord-Sud que nous avons complétée avec la rose des vents de la région de Laayoune dont est issue notre image satellitaire à haute résolution.

En effet, après avoir collecté des données sur la taille de la surface des dunes en fonction de leur angle (Fig.21), nous avons trouvé une

distribution normale où les plus grandes dunes étaient centrées sur  $\theta = 22,5$  degrés (ou NNE). De plus, l'histogramme produit par les données recueillies à l'aide de notre méthode a également montré que la plupart des dunes sont centrées sur le même angle  $\theta$ . Comme il s'agissait d'une valeur spécifique, nous avons décidé de rechercher une source de données externe supplémentaire pour confirmer ou infirmer les résultats obtenus par notre méthode de collecte de données.

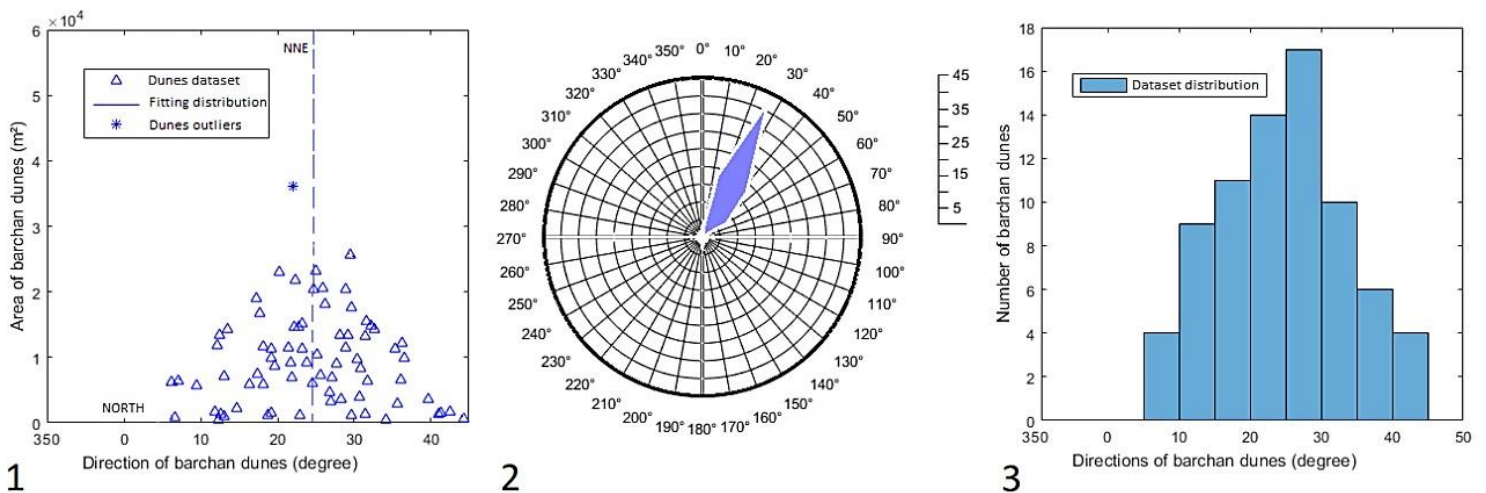


Fig.21 : Mesures des directions géométriques des dunes de sable barkhanes

1. Surface de la dune en fonction de son angle d'orientation
2. La rose des vents de la région de Tarfaya en Juillet 2003
3. L'histogramme des angles des dunes

Ainsi, nous avons constaté que la rose des vents qui nous a fourni la direction du vent dans la région d'où provient notre ensemble de données dans l'image satellite, montre bien que le vent dominant soufflait précisément à de 22,5 degrés (ou NNE). Par conséquent, cela a confirmé que notre approche basée sur l'apprentissage machine ainsi que le processus automatisé de collecte de données à partir d'images satellites pouvait mesurer très précisément les caractéristiques de l'allométrie des dunes de barkhanes et obtenir des résultats cohérents avec le terrain.

### 3.5 Conclusion

Nous avons présenté dans ce chapitre une approche intégrale qui automatise la collecte de mesures d'allométrie après détection et segmentation des barkhanes. En premier lieu nous avons amélioré la qualité de l'image, puis détecté les dunes barkhanes, ensuite, segmenté leur contour et enfin calculé les mesures d'allométrie. Nous avons aussi exploré leur corrélation et confirmé qu'elles étaient vérifiables.

Nous avons comparé les résultats obtenus avec ceux qui ont été trouvés dans (Elbelrhiti et al. 2005) pour des barkhanes présentes sur le terrain. Ainsi, que ce soit dans les régions de Laayoune ou dans la région de La Joya, il existe des relations similaires entre la largeur de la dune notée  $W$  et la somme des largeurs des cornes notée  $\Delta$ .

Bien que cette l'approche présentée dans ce chapitre soit extensive, elle reste limitée pour le cas de dunes barkhanes dont la forme est relativement régulière. Or, dans le désert, il arrive aux dunes avançant à vitesses différentes d'entrer en collision. Nous introduisons dans le chapitre suivant une nouvelle approche permettant de prendre en compte les dunes en collision, présentant des formes erratiques.

# Chapitre 4: La détection de collision de dunes Barkhanes et le transfert d'apprentissage

## 4.1 Introduction

La segmentation des dunes barkhanes se heurte à un problème conséquent lorsque ces dernières entrent en collision et perdent leur forme caractéristique en croissant. En effet, celle-ci présentent dans ce cas des formes très irrégulières. Nous présentons dans ce chapitre une nouvelle approche permettant de les isoler. Nous introduisons une variante du Deep Learning appelée Transfert d'Apprentissage, et nous la combinerons avec un partitionnement basé sur la fusion des données multispectrales et panchromatiques. Nous expliquons dans ce qui suit le mode opératoire sur les images satellitaires.

## 4.2 Les méthodes de détection, segmentation et allométrie des barkhanes:

### 4.2.1 L'amélioration d'image et la fusion des bandes multispectrales et panchromatiques

Nous utilisons dans ce chapitre la même image IKONOS, mais nous mettons à profit cette fois toutes les bandes multispectrales et panchromatiques présentes que l'on décrit dans le tableau suivant (Tab.5) qui présente les résolutions spatiales et spectrales des différentes bandes :

Bandes		Résolution spatiale	Longueur d'onde
Panchromatique		0.82 m/pixel	0.526 - 0.929 $\mu\text{m}$
Multi-spectrales	Infrarouge proche	4 m/pixel	0.757 - 0.853 $\mu\text{m}$
	R (Rouge)	4m/pixel	0.632 - 0.698 $\mu\text{m}$
	G (Vert)	4m/pixel	0.506 - 0.595 $\mu\text{m}$
	B (Bleu)	4m/pixel	0.445 - 0.516 $\mu\text{m}$

Tab.5 : Résolutions spatiales et spectrales de l'image satellitaire IKONOS utilisée

Les images satellite sont généralement affectées par le bruit qui peut être optique ou systémique. Par conséquent, l'utilisation d'une stratégie de réduction du bruit est essentielle. Nous avons commencé par utiliser un filtre bilatéral, représenté par l'équation (Eq.4.1), qui lisse l'image tout en préservant les bords, en utilisant une combinaison non linéaire de valeurs des pixels voisins.

$$I^{filtered}(x) = \frac{1}{W_p} \sum_{x_i \in \Omega} I(x_i) f_r(\|I(x_i) - I(x)\|) g_s(\|x_i - x\|) \quad (\text{Eq.4.1})$$

$I$  est l'image d'origine qui est filtrée.  $x$  correspond aux coordonnées du pixel à filtrer.  $\Omega$  est la fenêtre centrée en un pixel d'indice  $i$ , et  $g$  est une fonction Gaussienne pour lisser les différences de coordonnées.  $W$  est le poids attribué avec le noyau.

Ensuite, on utilise l'égalisation d'histogramme pour améliorer le contraste de l'image satellitaire, en distribuant les intensités de pixels sur l'histogramme. Ces opérations ont été appliquées sur les images multispectrales et panchromatiques. Enfin, nous avons mis à l'échelle et fusionné les images multispectrales et panchromatiques, en utilisant une interpolation bilinéaire pour produire des images multispectrales avec la résolution spatiale de l'image panchromatique.

#### 4.2.2 La segmentation par clustering pour isoler le couloir de dunes

Nous présentons ici une approche non supervisée pour la segmentation des dunes de sable, qui comprend deux étapes: la première est la conversion vers l'espace colorimétrique CIELAB, qui a été défini par la Commission internationale de l'éclairage (CIE), L étant la couche de luminosité, et a et b les couches de chromaticité codant les informations de couleur. Dans la deuxième étape, nous on prend en entrée l'image du laboratoire et on opère un regroupement (Clustering) basé sur la segmentation K-Means pour distinguer les différents aspects géologiques de la zone d'intérêt, y compris les dunes de sable. En effet, les bandes multispectrales dans les images satellites permettent d'obtenir des informations sur la nature du terrain en utilisant sa réflectance dans différentes longueurs d'onde. Plus précisément, nous pouvons distinguer les différentes compositions minérales de sable à partir des images satellites. Le choix du nombre de clusters et de la combinaison à utiliser sera présenté dans les résultats.

#### 4.2.3 Le Transfert d'Apprentissage comme variation du Deep Learning

Le transfert d'apprentissage est une approche utilisée pour amorcer l'apprentissage d'une nouvelle tâche, en transférant les connaissances d'une tâche similaire déjà apprise et en l'adaptant. Dans notre cas, on utilise l'architecture Deep Learning AlexNet.




Fig.22 Architecture du modèle Deep Learning AlexNet

AlexNet est un réseau neuronal convolutif d'apprentissage profond (CNN) qui a été introduit pour la première fois lors du concours ImageNet où il a surpassé les méthodes de pointe de 10%. Sa structure était composée de 8 couches: 3 couches connectées et 5 couches convolutives. La (Fig.22) illustre son architecture composée de 60 millions de paramètres et de 650 000 neurones au total. Ce modèle prend des images RGB à 3 canaux de taille  $227 \times 227$ , qui vont traverser ses couches consécutives avant d'être classées parmi les 1000 classes possibles. La première couche est une couche convolutionnelle avec 96 noyaux ayant une taille de  $11 \times 11 \times 3$  et une fonction d'activation non linéaire ReLU (Eq.4.2).

$$\emptyset(x) = \max(0, x) \text{ (Eq.4.2)}$$

Avec  $x$  l'entrée neuronale pondérée. La deuxième couche était une couche Overlapping Max Pooling qui conserve la profondeur, tout en échantillonnant la largeur et la hauteur des tenseurs. La bordure de valeur égale à 2 est utilisée en anticipation du chevauchement entre des fenêtres adjacentes afin de réduire le taux d'erreur. La couche suivante est une autre couche convolutionnelle, suivie d'une autre couche d'Overlapping Max Pooling, puis de trois couches convolutionnelles, puis une couche Max Pooling simple, suivie de deux couches entièrement connectées, et enfin d'un classificateur softmax avec 1000 étiquettes de classe. La couche Softmax est une couche de normalisation qui prend en entrée un vecteur de dimension  $N$ , et le convertit en un vecteur de probabilités  $N$  qui est proportionnel aux exponentielles des éléments d'entrée (Eq.4.3), telles que les valeurs du vecteur résultant sont délimitées dans l'intervalle  $[0,1]$ .

$$\sigma(x)_i = \frac{e^{x_i}}{\sum_{j=1}^N e^{x_j}} \text{ (Eq.4.3)}$$

Avec  $\sigma$  la fonction softmax,  $i = 1, \dots, N$  correspond à l'indice de l'élément dans le vecteur à  $N$  dimensions. Ces différentes couches visent toutes à atténuer le problème de diminution du gradient pendant l'entraînement de rétropropagation (Back Propagation). En effet, les couches convolutives produisent des Maps basées sur l'idée qu'un objet pourrait être trouvé dans différentes zones de l'image, et ainsi permettent la mise en commun des traitements et réduit la dimensionnalité.

L'approche de transfert d'apprentissage consiste essentiellement à réutiliser les valeurs de poids du réseau neuronal profond formé, tout en remplaçant les dernières couches par de nouvelles qui sont réutilisée pour fournir un modèle mieux adapté à l'objet cible et à la tâche à accomplir. De plus, il nécessite moins de temps et de puissance de calcul. En effet, les poids d'initialisation sont optimaux et non aléatoires. Aussi, comme les premières couches d'un réseau neuronal d'apprentissage profond extraient des fonctionnalités plus simples, ces caractéristiques et leurs poids correspondants restent similaires à condition que le modèle ait soit pré-entraîné sur des milliers d'images. En effet, le Deep Learning a des milliers de paramètres libres à spécifier, et qui nécessitent des milliers d'images d'entraînement, afin de trouver les valeurs optimales des paramètres, ce qui est un inconvénient car ce modèle dit Big Data ne peut pas être directement appliqué pour l'entraînement des applications dites Small Data telles que celle que nous avons entre nos mains, où la quantité de données annotées est limitée. Par conséquent, l'utilisation du transfert d'apprentissage est essentielle pour conserver les avantages du Deep Learning, tout en s'adaptant aux nombre limité de données, car il n'a besoin de ré-entraîner que les dernières couches qui correspondent à des informations de haut niveau qui sont importantes pour la décision finale.

Nous avons donc choisi d'utiliser le Transfer d'Apprentissage car la taille de notre base de données est relativement petite, ce qui est généralement le cas dans des applications spécifiques d'imagerie satellitaire et de télédétection, telles que la détection des dunes de sable.

Le Transfert d'Apprentissage nous permet de conserver la puissance prédictive d'un modèle Deep Learning. De plus, la puissance de traitement requise par le Deep Learning est énorme par rapport au Transfer Learning, qui ne nécessite pas autant d'itérations pour converger. Ainsi, l'utilisation de l'apprentissage par transfert a nécessité moins de cycles CPU et moins de temps.

#### 4.3 Résultats obtenus

Notre approche commence par l'amélioration de la qualité d'image et la fusion des bandes multispectrales et panchromatique. La figure suivante illustre un échantillon exemple (Fig.23)



Fig.23 : De gauche à droite : image originale, application de l'histogramme d'égalisation, application du filtre bilinéaire

Après avoir amélioré la qualité de l'image, nous sommes avons commencé par expérimenter différents nombres de clusters  $K = \{2,3,4,5,6\}$  afin de trouver le nombre optimal pour notre application.

Nous avons sélectionné au hasard un ensemble de 3 images multispectrales, que nous avons converties dans l'espace colorimétrique Lab, afin d'isoler les informations chromatiques dans les couches a et b. Nous avons observé les résultats K-Means que nous avons montrés dans la première ligne de (Fig.26): Pour  $K = 2$  et  $K = 3$ , les classes sous-segmentaient l'image.

En effet, bien que le couloir central des dunes soit bien segmenté, cependant, les dunes qu'il contenait, que nous considérons comme notre premier plan, ne se distinguaient pas de leur entourage immédiat, qui était considéré comme un arrière-plan dans notre application. Pour  $K = 5$  et  $K = 6$ , les classes sur-segmentaient l'image satellite car les dunes, qui étaient notre objet d'intérêt, car elles étaient divisées en plusieurs régions correspondant à différentes luminosités causées par la réflexion du soleil sur leurs surfaces courbes.

Par conséquent, le nombre optimal de clusters que nous avons sélectionnés pour le traitement ultérieur était  $K = 4$ , car cela nous a permis de classer les régions d'image en 4 catégories correspondant à des éléments géologiques distinctes: les 2 premières classes ont été considérées comme un arrière-plan car elles correspondaient à un substrat rocheux solide. Les troisièmes et quatrièmes classes correspondaient au sable de deux couloirs de dunes différents. Nous étions intéressés par le couloir principal des dunes qui contenait le plus grand nombre de dunes barkhanes et était au centre de l'image. Le couloir de dunes secondaires qui avait une composition minérale différente et donc une réponse spectrale différente. De plus, il était partiellement visible et il se trouvait en majorité hors des limites de notre image satellite.

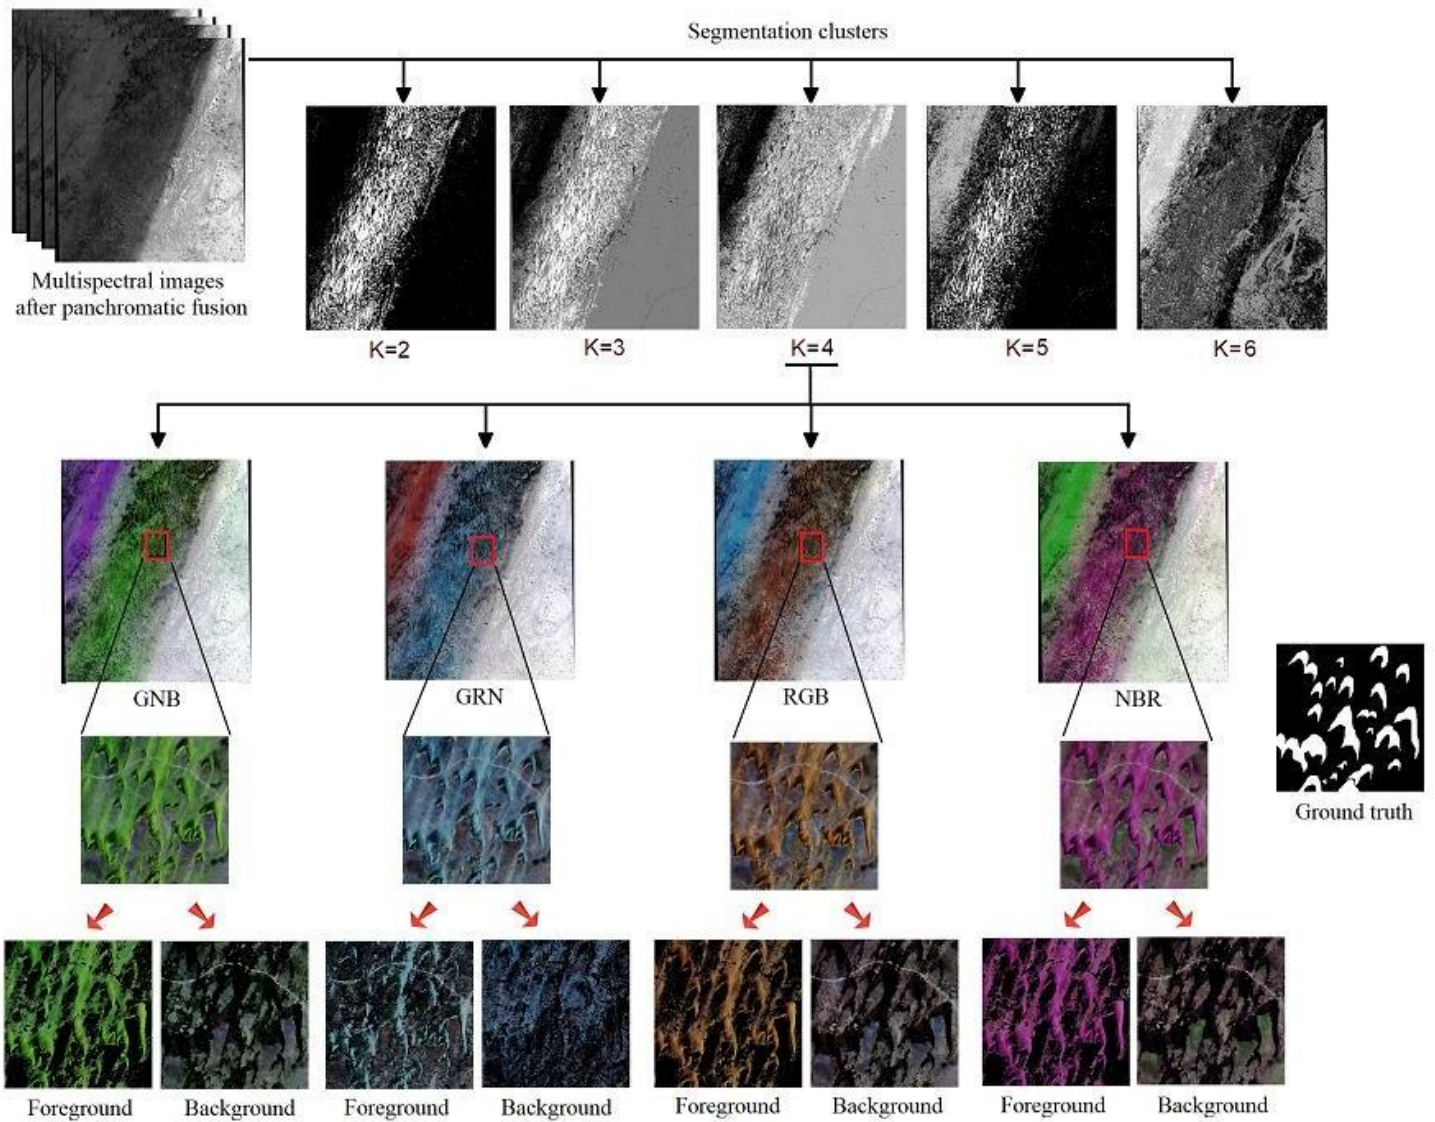


Fig.24 Segmentation des combinaisons de bandes, et échantillon d'évaluation

Par conséquent, maintenant que nous avons identifié la classe qui sera utilisée comme masque, nous procédons à la recherche de la meilleure combinaison à 3 canaux des 4 images multispectrales, qui fournit les meilleurs résultats de segmentation. À cette fin, nous avons expérimenté les 4 possibilités de combinaisons de bandes multispectrales à 3 canaux: GNB, GRN, RGB et NBR qui ont été

montrées dans la deuxième ligne de (Fig 24). L'évaluation suivante a été réalisée en sélectionnant un échantillon à partir de l'image satellite représentant la zone la plus problématique de l'image satellite, car elle contenait des dunes barkhanes, leurs collisions et un champ nu, y compris une route. Nous avons également annoté une image de référence de ce patch d'évaluation qui représentait des dunes. Les résultats de l'évaluation statistique des 4 combinaisons d'images satellites ont été présentés dans le (Tab 4 .2).

Statistical Evaluation		Multispectral Band Combinations							
		GNB		GRN		NBR		RGB	
		Actual class		Actual class		Actual class		Actual class	
		sand	not sand	sand	not sand	sand	not sand	sand	not sand
Predicted	sand	10081	22644	8159	28208	10270	20599	9970	16527
	not sand	3157	30167	5079	24603	2968	32212	3268	36284
Total		13238	52811	13238	52811	13238	52811	13238	52811
Accuracy		0.6094		0.496		0.6432		0.7003	
Precision (PPV)		0.3081		0.2244		0.3327		0.3763	
F1-Score		0.4387		0.329		0.4657		0.5018	
Recall (TPR)		0.7615		0.6163		0.7758		0.7531	
Specificity (TNR)		0.5712		0.4659		0.6099		0.6871	
Youden J-Statistic		0.3327		0.0822		0.3857		0.4402	

Tab.6 : Evaluation de la segmentation des différentes combinaisons de bandes

Le tableau (Tab.6) présente le résultat d'évaluation des différentes bandes en utilisant plusieurs indicateurs statistiques qui ont montré que la meilleure segmentation a été faite en utilisant la combinaison RGB, avec une précision de 70%, un rappel de 75% et une statistique de Youden de 0,44. Ces résultats étaient bons compte tenu du fait qu'ils correspondent au patch montrant la partie la plus problématique de l'image satellite, et que la segmentation à ce stade a déjà éliminé les grandes zones environnantes contenant le substrat rocheux solide avec une précision de pratiquement 100%.

Nous avons utilisé le Deep Learning d'AlexNet comme base de notre apprentissage par transfert. Après avoir annoté 1000 patches d'images extraits de l'image satellite comme en trois classes différentes correspondant à des dunes barkhanes, une collision de dunes ou un champ nu, nous avons augmenté l'ensemble de données et lancé l'algorithme de rétropropagation avec le graphique montré dans la (Fig.25).




Fig.25 Entraînement du Transfert d'Apprentissage

Après 530 itérations sur 10 époques, en utilisant une taille de lot minimum de 10 images, et une fréquence de validation de 100 itérations, nous avons obtenu une précision de 84,01%. Les exemples d'ensemble d'entraînement et de test sont montrés dans la (Fig.26).

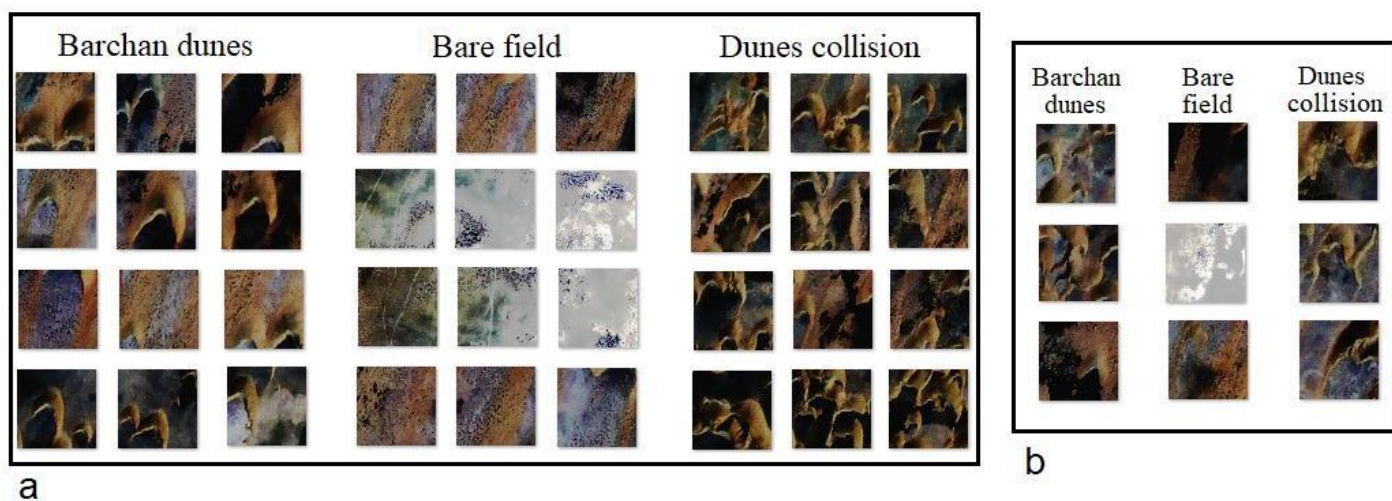


Fig.26 Echantillons d'images satellitaires représentant les 3 classes utilisées

a : Exemple de données d'entraînement

b : Exemple de données de test

Nous avons remarqué que les erreurs de classification se sont produites principalement entre les classes de dunes barkhanes et les collisions de dunes car il était parfois difficile de classer les dunes barkhanes partiellement occluses. Inversement, les détections de champs nus, y compris les parcelles avec des traînées de sable, ont retourné des résultats excellents.

#### 4.4 Conclusion

Dans ce quatrième chapitre, nous avons pu inclure le cas spécial des dunes barkhanes qui prennent des formes chaotiques, suite à des collisions avec d'autres barkhanes. Pour ce faire, nous avons opéré une fusion des informations spatiales et spectrales pour opérer un partitionnement semi-supervisé de l'image satellitaire, qui nous a permis de segmenter le couloir de dunes, ensuite, nous avons

introduit pour la première fois l'utilisation du Transfert d'apprentissage basé sur le Deep Learning pour la détection des collisions de dunes barkhanes dans les images satellitaires à haute résolution, qui a permis de retourner de très bons résultats en termes de précision.

## Conclusion générale

Au cours de cette thèse, nos travaux de recherche ont porté sur la segmentation d'images satellitaires de dunes barkhanes par des méthodes d'apprentissage machine, afin de produire de nouvelles approches précises et robustes permettant d'automatiser la collecte des données et prenant en compte la variabilité du terrain.

Le premier chapitre a été consacré aux modèles et principes de l'apprentissage machine. Nous avons commencé par dresser un parallèle avec l'apprentissage humain, puis défini les bases de l'apprentissage à partir de données, différencié les différents paradigmes d'apprentissage : supervisé, non supervisé et par renforcement. Nous avons par la suite énoncé une formalisation mathématique pour ces méthodes, ainsi que leurs outils d'estimation d'erreur et de réduction du bruit. Nous avons aussi discuté de la théorie de la généralisation, ainsi que les compromis entre biais et variance. Nous avons illustré des concepts concrets comme la courbe d'apprentissage, les notions de compromis entre sous apprentissage et sur apprentissage. Nous avons enfin présenté des méthodes linéaires et non linéaires d'apprentissage machine présents dans la littérature, identifié leurs points forts et leurs limites.

Le deuxième chapitre a été consacré à notre première contribution pour la segmentation des dunes barkhanes en utilisant les descripteurs de texture et de région avec des classificateurs statistiques. Nous avons divisé le problème en deux parties : La première partie consistait à segmenter l'arrière-plan en combinant plusieurs descripteurs prenant en compte la différence de texture entre les dunes et le terrain. Nous avons sélectionné un sous ensemble de descripteurs de Haralick en se basant sur le test statistique de Kolmogorov-Smirnov, permettant ainsi une segmentation rapide et avec un indice de Youden élevé. La seconde étape consistait à affiner la segmentation des dunes en utilisant une

approche multi échelle qui combinait les descripteurs de région MSER, ainsi que les détecteurs SURF, en utilisant une validation croisée. La précision des résultats obtenus était très satisfaisante sur l'image du satellite MRO qui représentait un groupe de dunes Barkhanes sur la surface Mars. Cependant, nous avons rencontré des limitations dans le cas des images IKONOS où le terrain sablonneux se confondait avec les bordures des dunes barkhanes.

Dans le troisième chapitre, nous avons proposé une nouvelle approche qui a non seulement amélioré les résultats de segmentation, mais introduit un processus de bout en bout, commençant à partir d'images satellitaires à haute résolution, en passant par l'amélioration d'image, la détection des dunes, la segmentation de leur contours, et aboutit à la génération automatique de données d'allométrie. A cette fin, nous avons fait l'apprentissage d'une cascade hiérarchique de classificateurs utilisant les ondelettes de Haar. Les dunes détectées sont ensuite segmentées par une amélioration que nous avons introduite sur le modèle de forme actif. En effet, en plus de l'analyse de Procrustes, de la réduction de dimensionnalité ACP existantes, nous avons introduit une approche par apprentissage machine utilisant les descripteurs SIFT avec un classificateur SVM, afin de réaliser la correspondance du contour avec les bordures des dunes barkhanes. Par la suite, nous avons mis à contribution les contours détectés et nous avons introduit un nouveau modèle d'allométrie normalisé qui permet de calculer les largeurs, direction, largeur des cornes et d'autres caractéristiques morphologiques des dunes barkhanes, et de les comparer. Enfin, nous avons exploré des corrélations entre ces mesures qui ont révélé des résultats statistiques que nous avons confirmés par les études présentes dans la littérature exposant des résultats similaires pour des études faites par des géologues sur le terrain.

Dans le quatrième chapitre, nous avons tenté de généraliser notre approche au cas des dunes barkhanes qui prennent des formes non conventionnelles, suite à des interactions avec d'autres dunes

barkhanes, les rendant très difficiles à traiter avec les méthodes précédentes. Nous avons donc commencé par fusionner les informations spatiales et spectrales pour opérer un partitionnement semi-supervisé de l'image satellitaire, qui nous avait permis de segmenter le couloir de dunes du terrain environnant, limitant ainsi la zone de recherche des dunes. Ensuite, nous avons introduit pour la première fois l'utilisation du Transfert d'apprentissage basé sur le Deep Learning pour la détection des collisions de dunes barkhanes dans les images satellitaires à haute résolution, qui de plus a retourné des résultats très bons en termes de précision.

Ainsi, nous avons pu traiter l'ensemble des dunes Barkhanes présentes sur les images satellitaire à haute résolution à notre disposition. Nous avons pu non seulement développer des approches combinées, mais aussi, apporter des améliorations sur une ou plusieurs étapes à la fois. Nous avons aussi appris à utiliser et à tirer profit de points forts des différentes méthodes d'apprentissage machine et avons développé une réflexion sur la matière. Cependant, il existe toujours des axes d'améliorations, et c'est ce qui fait la beauté de la recherche scientifique. Nous citerons dans notre cas :

- Les dunes étant des objets 3D, utiliser des méthodes d'apprentissage machine pour générer un DSM (Digital Surface Model) du terrain.
- Généraliser les méthodes développées à des images satellitaires prises à des périodes successives afin de réaliser une étude multi temporelle permettant le suivi des dunes barkhanes.
- Constituer une base de données de barkhanes issue de plusieurs images satellitaires afin de servir de Benchmark pour les chercheurs.

# Bibliographie

Abu-Mostafa, Y. S., Magdon-Ismaïl, M., Lin, H. 2012. Learning from data: a short course. [United States]: AMLBook.com.

Alahi, A., Ortiz, R., Vandergheynst, P. 2012. FREAK: Fast retina keypoint. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 510-517. 10.1109/CVPR.2012.6247715.

Azzaoui M.A, Elbelrhiti H., Chaouki I. E., Masmoudi L. 2019. «Segmentation of crescent sand dunes in high resolution satellite images using a support vector machine for allometry», International Journal of Advanced Computer Science and Applications. Vol.10, No.11, 2019, p. 191-198

Azzaoui M.A, Elbelrhiti H., Chaouki I. E., Masmoudi L. 2020. « Barchan sand dunes collisions detection in high resolution satellite images based on image clustering and Transfer Learning», International Journal of Advanced Computer Science and Applications

Azzaoui M.A, Adnani.M., Elbelrhiti H., Chaouki I. E., Masmoudi L. 2016. «Detection of Barchan dunes in High Resolution Satellite Images», The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLI-B7, 2016, p. 154-160, XIII ISPRS Congress, Prague, Czech Republic

Azzaoui M.A, Adnani.M., Elbelrhiti H., Chaouki I. E., Masmoudi L. 2016. Texture Segmentation of Barchan Dunes in High Resolution Satellite Images, 8th International Workshop on sand/Duststorms and Associated Dustfall. Lisbon, Portugal, p.53

Azzaoui M.A, Elbelrhiti H., Chaouki I. E., Masmoudi L. 2019. «Detection of crescent sand dunes contours in satellite images using an active shape model with a cascade classifier», The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-4/W12, 2019, p. 17-24. 5th International Conference on Geoinformation Science. Casablanca, Morocco.

Azzaoui M.A, Adnani.M., Elbelrhiti H., Chaouki I. E., Masmoudi L. 2015. Evaluation of Edge Detection Techniques in High Resolution Satellite Images of Barchan Dunes», 2015 International Conference of Geospatial Techniques in Geosciences, Taza, Morocco.

Azzaoui M.A, Adnani.M., Elbelrhiti H., Chaouki I. E., Masmoudi L. 2015 « Morphological characterization of Barchans dunes using spline curves», First International Congress: ISEE GEOMATICS, Tataouine, Tunisia, 2015.

Benenson, R., Omran, M., Hosang, J., Schiele, B. 2015.: Ten years of pedestrian detection, what have we learned? In: Agapito, L., Bronstein, M.M., Rother, C. (eds.) ECCV Workshops. LNCS, vol. 8926, pp. 613–627. Springer, Heidelberg.

Bengio, Y., LeCun, Y., Hinton, G. 2015. Deep Learning. Nature 521: 436-44.

Bishop, M.A., 2010. Comparative nearest neighbor analysis of megabarchanoid dunes, Ar Rub al Khali sand sea: the application of geographical indices to the understanding of dune field selforganization, maturity and environmental change. *Geomorphology* 120, 186–194.

Blaschke T. 2010., Object based image analysis for remote sensing, *ISPRS Journal of Photogrammetry and Remote Sensing*, Volume 65, Issue 1, 2010, Pages 2-16, ISSN 0924-2716, DOI: 10.1016/j.isprsjprs.2009.06.004.

Blanco P. D., Metternicht, G. I. Del Valle H. F., Sione. W. 2007. Assessment of TERRA-ASTER and RADARSAT imagery for discrimination of dunes in the Valdes peninsula: an object oriented approach *Revista de Teledetección*. ISSN: 1133-0953. 2007. 28: 87-96.

Blumberg, D.G., 1998. Remote sensing of desert dune forms by polarimetric Synthetic Aperture Radar (SAR). *Remote Sensing of Environment* 65, 204–216.

Bouget D., Benenson. R., Omran, M. , Riffaud, L. Schiele, B., Jannin P. 2015. "Detecting Surgical Tools by Modelling Local Appearance and Global Shape," in *IEEE Transactions on Medical Imaging*, vol. 34, no. 12, pp. 2603-2617 doi: 10.1109/TMI.2015.2450831.

Bourke, M.C., Edgett, K.S., Cantor, B.A., 2008. Recent aeolian dune change on Mars. *Geomorphology* 94, 247–255.

Calonder. M, Lepetit V., Strecha C., Fua P. 2010, "BRIEF: Binary Robust Independent Elementary Features", 11th European Conference on Computer Vision (ECCV), Heraklion, Crete. LNCS Springer.

Clausi D. A. 2002. An analysis of co-occurrence texture statistics as a function of grey level quantization, *Can. J. Remote Sensing*, vol. 28, no.1, pp. 45-62.

Chen, Y., Lin, Z., Zhao, X., Wang, G., Gu, Y. 2014. Deep learning-based classification of hyperspectral data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 7 (6), 2094–2107.

Dalal N. and Triggs. B.. 2005. Histograms of oriented gradients for human detection. In *CVPR*.

Darshana M., Asim B. 2017. Comparison of Feature Detection and Matching Approaches: SIFT and SURF. *GRD Journals- Global Research and Development Journal for Engineering | Volume 2 | Issue 4 | ISSN: 2455-5703*.

Elbelrhiti, H., 2005. *Morphodynamique des barkhanes: Etude des dunes du Sud-Ouest Marocain*. Thèse Université Paris VII, France. 165p.

Elbelrhiti, H., Claudin, P., and Andreotti, B., 2005. Field evidence for surface-wave-induced instability of sand dunes. *Nature*, vol 437. p. 720-723.

Elbelrhiti, H., Claudin, P., and Andreotti, B., 2008. Barchan dunes corridors: Field characterization and investigation of control parameters, *J. Geophys. Res.* Vol 13. F02S15. doi:10.1029/2007JF000767.

Elbelrhiti, H., Dewitte, O., Montanarella, L., 2010. Commentaire sur l'article intitulé « Essai de morphométrie sur un système dunaire du Sud-Ouest marocain à partir d'une image Landsat » [*Sécheresse* 2010 ; 21(1) :54-62]. *Téledétection*, vol. 9, n. 2, p. 151-155

Elbelrhiti, H., Douady, S., 2011. Equilibrium versus disequilibrium of barchan dunes. *Geomorphology*, vol. 125, p.558-568.

Elbelrhiti, H. and Hargitai H: 2015. *Encyclopedia of Planetary Landforms*, Chapter: Barchan, p123, Publisher: Springer New York.

Ethan R., Rabaud V., Konolige K., Bradski R. 2011: ORB: An efficient alternative to SIFT or SURF. *ICCV 2011*: 2564-2571.

Fenton, L. K., 2006. Dune migration and slip face advancement in the Rabe Crater dunefield, Mars. *Geophys. Res. Lett.*

Forssén P. 2007. Maximally stable colour regions for recognition and matching. In *Computer Vision and Pattern Recognition, 2007. CVPR,,07. IEEE Conference on*, pages 1-8. IEEE.

Fryberger, S. G., and Deane, G. 1979. Dunes forms and wind regims. In McKee, E.D., ed, *A study of global sand seas:US. Geol. Surv. Prof Paper 1052*, p. 137-170

Goodfellow, I.J., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. *Generative Adversarial Networks*. 2014. arXiv:1406.2661

Hansen, C.J., Bourke,M.C., Bridges, N.T., Byrne, S., Colon, C., Diniega, S., Dundas, C., Herkenhoff,K., McEwen, A., Mellon, M., Portyankina, G., Thomas, N., 2011. Seasonal erosion and restoration of Mars' Northern Polar Dunes. *Science* 331, 575-578.

Haralick, R. M Shanmugam K., and I. Dinstein, 1973. Textural Features of Image Classification, *IEEE Transactions on Systems, Man and Cybernetics*, vol. SMC-3, no. 6, Nov 1973.

Herbert B., Ess A., Tuytelaars T., Van Gool, L. 2008. Speeded- Up Robust Features (SURF). *Comput. Vis. Image Underst.* 110, 3 (June 2008), 346-359. DOI=<http://dx.doi.org/10.1016/j.cviu.2007.09.014>.

Hersen, P., 2005. Flow effects on the morphology and dynamics of aeolian and subaqueous barchan dunes. *Journal of Geophysical Research* 110 (F04S07). doi:10.1029/2004JF000185.

Hochreiter, S. 1991. Untersuchungen zu dynamischen neuronalen Netzen (Diploma thesis), Institut für Informatik, Lehrstuhl Prof. Brauer, Technische Universit München, Advisor: J. Schmidhuber.

KamHo T. 1995. *Proceedings of the 3rd International Conference on Document Analysis and Recognition, Montreal, QC, 14-16 August 1995*. pp. 278-282

Kocurek, G. A., & Ewing, R. C. 2005. Aeolian dune field self-organization - Implications for the formation of simple versus complex dune-field patterns. *Geomorphology*, 72(1-4), 94-105. <https://doi.org/10.1016/j.geomorph.2005.05.005>

Krizhevsky, A., Sutskever, I., Hinton, G., 2012. Imagenet classification with deep convolutional neural networks. In: *Advances in Neural Information Processing Systems*. pp. 1097-1105.

Li, C.; Wang, J.; Wang, L.; Hu, L.; Gong, P. 2014. Comparison of Classification Algorithms and Training Sample Sizes in Urban Land Classification with Landsat Thematic Mapper Imagery. *Remote Sens.* 2014, 6, 964-983.

Liao S., Xiangxin Z., Zhen L., Lun Z. and Stan Z. 2014. Learning Multi-scale Block Local Binary Patterns for Face Recognition. *International Conference on Biometrics (ICB)*, 2007, pp. 828-837.

Litjens, G., Kooi, T., Bejnordi, B.E., Setio, A.A.A., Ciompi, F., Ghafoorian, M., Sanchez, C.I., 2017. A survey on deep learning in medical image analysis. *Med. Image Anal.* 42, 60-88.

Loizeau D., Poulet F., Horgan B., Mangold N., Michalski J., Bishop J. 2015. Mawrth Vallis clay unit: probing the early Mars Habitability, Climate and Origin of Life. 2nd Landing Site Workshop for the 2020 Mars Rover mission

Lowe, D. G. 1999. "Object recognition from local scale-invariant features" (PDF). *Proceedings of the International Conference on Computer Vision*. 2. pp. 1150-1157. doi:10.1109/ICCV.1999.790410.

Matas J., O. Chum, M. Urban, and T. Pajdla. 2002. "Robust wide baseline stereo from maximally stable extremal regions." *Proc. of British Machine Vision Conference*, 384-396.

Matheron. G. 1967. *Éléments pour une Théorie des Milieux Poreux*. Masson, Paris

McKee, E.D., 1979. Introduction to a study of global sand seas. In: McKee, E.D. (Ed.), *A Study of Global Sand Seas: United States Geological Survey, Professional Paper*, 1052, pp. 3-19.

Ojala T., Pietikäinen M. 1994, "Performance evaluation of texture measures with classification based on Kullback discrimination of distributions", *Proceedings of the 12th IAPR International Conference on Pattern Recognition (ICPR 1994)*, vol. 1, pp. 582 - 585.

Pan, S. J., and Qiang Y. 2009. "A survey on transfer learning." *IEEE Transactions on knowledge and data engineering* 22.10 : 1345-1359.

Perlish. C. 2011. *Learning Curves in Machine Learning*. IBM Research Report.

DOI: 10.1007/978-0-387-30164-8\_452

Schiewe, J. 2012. Segmentation of high-resolution remotely sensed data - Concepts, applications and problems. *International Archives of Photogrammetry and Remote Sensing*. 34.

Scheidt, S., Ramsey, M., Lancaster, N., 2010. Determining soil moisture and sediment availability at White Sands Dune field, New Mexico, from apparent thermal inertia data. *Journal of Geophysical Research* 115, F02019.

Schiewe, J. 2012. Segmentation of high-resolution remotely sensed data - Concepts, applications and problems. *International Archives of Photogrammetry and Remote Sensing*. 34.

Schmidhuber, J., 2015. Deep learning in neural networks: an overview. *Neural Networks* 61, 85-117.

Sah, S. 2020. Machine Learning: A Review of Learning Types. 10.20944/preprints202007.0230.v1.

Simonyan, K., Zisserman, A., 2014. Very deep convolutional networks for large-scale image recognition. arXiv. Available: <https://arxiv.org/pdf/1409.1556.pdf>.  
He, K., Zhang, X., Ren, S., Sun, J., 2016. Deep residual learning for image recognition. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770-778.

Soh L. , C. Tsatsoulis, 1999. Texture Analysis of SAR Sea Ice Imagery Using Gray Level Co-Occurrence Matrices, *IEEE Transactions on Geoscience and Remote Sensing*, vol. 37, no. 2.

Szegedy, C., Ioffe, S., Vanhoucke, V., Alemi, A.A., 2017. Inception-v4, inception-resnet and the impact of residual connections on learning. In: *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence (AAAI-17)*, pp. 4278-4284

Tomasi, C., and R. Manduchi. 1998. "Bilateral Filtering for Gray and Color Images". *Proceedings of the 1998 IEEE® International Conference on Computer Vision*. Bombay, India. Jan 1998, pp. 836-846.

Tsoar, H., 2001. Types of Aeolian Sand Dunes and Their Formation. *Geomorphological Fluid Mechanics*. N.J. Balmforth and A. Provenzale (Eds.): LNP 582, pp. 403-429. c Springer-Verlag Berlin Heidelberg 2001.

UNCCD, 2008: United Nations Convention to Combat Desertification in those countries experiencing serious drought and/or desertification, particularly in Africa. UNCCD explanatory leaflet, UNCCD Secretariat, Bonn.

Vapnik V., 1982. Estimation of Dependencies. Based on Empirical Data, Springer-Verlag, New York

Vermeesch, P., Drake, N., 2008. Remotely sensed dune celerity and sand flux measurements of the world's fastest barchans (Bodélé, Chad). *Geophysical Research Letters* 35, L24404.

Viola P., Jones. M. 2001. Rapid Object Detection using a Boosted Cascade of Simple Features. *Conference on Computer Vision and Pattern Recognition (CVPR)*, 2001, pp. 511-518

Wolfe, S.A., Hugenholtz, C.H., 2009. Barchan dunes stabilized under recent climate warming on the northern Great Plains. *Geology* 37, 1039–1042.

Zhu, X.X., Tuia, D., Mou, L., Xia, G., Zhang, L., Xu, F., Fraundorfer, F., 2017. Deep learning in remote sensing: a comprehensive review and list of resources. *IEEE Geosci. Remote Sens. Mag.* 5 (4), 8–36.


Zhang, L., Zhang, L., Du, B., 2016. Deep learning for remote sensing data: a technical tutorial on the state of the art. *IEEE Geosci. Remote Sens. Mag.* 4 (2), 22–40.

# Annexe

Image panchromatique IKONOS:



Image MRO :



## Publications

Azzaoui M.A, Elbelrhiti H., Chaouki I. E., Masmoudi L. 2020. Barchan sand dunes collisions detection in high resolution satellite images based on image clustering and Transfer Learning, 2020 International Journal of Advanced Computer Science and Applications, Vol.11, No.1

Azzaoui M.A, Elbelrhiti H., Chaouki I. E., Masmoudi L. 2019. Segmentation of crescent sand dunes in high resolution satellite images using a support vector machine for allometry», International Journal of Advanced Computer Science and Applications. Vol.10, No.11, 2019, p. 191-198

Azzaoui M.A, Adnani.M., Elbelrhiti H., Chaouki I. E., Masmoudi L. 2019. Detection of crescent sand dunes contours in satellite images using an active shape model with a cascade classifier», The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-4/W12, 2019, p. 17-24. 5th International Conference on Geoinformation Science. Casablanca, Morocco.

Adnani.M., Azzaoui M.A, Elbelrhiti H., Chaouki I. E., Masmoudi L. 2018. «Investigation of reddening patterns of dune sands – The megaBarchans of Alghord Lahmar (Khniouss National Park, South-West of Morocco) » 2018.Catena. 162, pp. 230-244

Adnani.M., Azzaoui M.A, Elbelrhiti H., Chaouki I. E., Masmoudi L. 2016. «Yerdi sand dunes (Erfoud area, southeastern of Morocco): color, composition, sand's provenance, and transport pathways. 2016, Arabian Journal of Geosciences, 9(5),366

Azzaoui M.A, Adnani.M., Elbelrhiti H., Chaouki I. E., Masmoudi L. 2016. Detection of Barchan dunes in High Resolution Satellite Images», The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLI-B7, 2016, p. 154-160, XIII ISPRS Congress, Prague, Czech Republic

Azzaoui M.A, Adnani.M., Elbelrhiti H., Chaouki I. E., Masmoudi L. 2016. Texture Segmentation of Barchan Dunes in High Resolution Satellite Images, 8th International Workshop on sand/Duststorms and Associated Dustfall. Lisbon, Portugal, 2016, p.53

Azzaoui M.A, Adnani.M., Elbelrhiti H., Chaouki I. E., Masmoudi L. 2015.  
Evaluation of Edge Detection Techniques in High Resolution Satellite Images of Barchan Dunes, International Conference of Geospatial Techniques in Geosciences, Taza, Morocco.

Azzaoui M.A, Adnani.M., Elbelrhiti H., Chaouki I. E., Masmoudi L. 2015.  
Morphological characterization of Barchans dunes using spline curves», First International Congress: ISEE GEOMATICS, Tataouine, Tunisia.

Année Universitaire : 2019/2020

**Résumé :**

*L'étude des dunes de sable est essentielle pour comprendre et prévenir le phénomène de désertification. La collecte de données sur le terrain est une tâche ardue sachant le nombre important de dunes. Nous avons contribué avec une nouvelle approche automatisant la collecte de données des dunes à partir d'images satellitaires par l'apprentissage automatique pour la segmentation. Nous nous intéressons aux dunes Barkhanes car elles sont les plus rapides. Leur segmentation pose des problèmes dus à la variabilité de leur luminosité, taille, orientation et forme non rigide. Pour les surmonter, nous avons exploité la texture de l'image avec des descripteurs et des indicateurs statistiques, obtenant ainsi de bons résultats que nous avons améliorés avec une approche d'apprentissage machine combinant un classificateur hiérarchique en cascade pour la détection des positions, et une nouvelle variante du modèle de forme active que nous avons introduite pour réaliser la correspondance des contours. Nous avons aussi développé un modèle d'allométrie. Enfin, nous avons généralisé notre solution pour le cas des Barkhanes en collision, présentant des formes erratiques, en introduisant l'utilisation du transfert d'apprentissage, variante du Deep Learning. Nos méthodes ont été testées sur différentes images satellitaires à haute résolution. Les résultats expérimentaux étaient très satisfaisants en précision et en robustesse.*

**Mots-clés :** *Segmentation d'image, Apprentissage Machine, détection d'objets, imagerie satellitaire à haute résolution, dunes de sable Barkhanes.*

**Abstract:**

*The study of sand dunes is essential to understand and prevent the desertification phenomenon. Gathering data from the field is a labor intensive task, as deserts contain a large number of moving sand dunes. In this work, we contributed with a novel approach to automate their data collection, from High Resolution Satellite Images, using machine learning for image segmentation. We focused on Barchans as they were the fastest moving dunes. We faced many obstacles to segment these objects, due to the variability of their luminosity, size, orientation and non-rigid shape. To overcome these issues, we took advantage of image texture and used descriptors and statistical indicators, which provided good results. We improved them using a Machine Learning approach in which we combined a hierarchical cascade classifier for the detection of Barchans, with a new variation of Active Shape Model which we introduced for contour matching.. Moreover, we developed a new model for allometry. Finally, we generalized our solution, by taking into account colliding Barchans, which have erratic shapes, by introducing Transfer Learning, a variation of Deep Learning, to achieve the detection of Barchans dunes collisions. Our methods were tested on multiple high resolution satellite images. The experimental results were satisfying both in accuracy and robustness.*

**Keywords:** *Image segmentation, Machine Learning, object detection, High Resolution Satellite Images, Barchan sand dunes.*

Année Universitaire : 2019/2020