جامعة سيدي محمد بن عبد الله بفاس
ⵜⴰⵙⴷⴰⵡⵉⵜ ⵙⵉⴷⵉ ⵎⵓⵃⵎⵎⴰⴷ ⴱⵏ ⵄⴱⴷⵍⵍⴰⵀ ⵏ ⴼⴰⵙ
UNIVERSITÉ SIDI MOHAMED BEN ABDELLAH DE FES

كلية العلوم ظهر المهراز فاس
ⵜⴰⵖⵉⵡⴰⵍⵜ ⵏ ⵜⵎⵙⵙⵓⵏⵜ ⴹⵀⴰⵔ ⵍⵎⵀⵔⴰⵣ ⴼⴰⵙ
FACULTE DES SCIENCES DHAR EL MAHRAZ FES

N° d'Ordre : **33/2021**

Formation Doctorale : STIC

Discipline : Physique

Spécialité : Génie électrique

Laboratoire de LISAC

THESE DE DOCTORAT

Présentée par

Youssef FILALI

Aide au diagnostic du cancer de la peau : Ingénierie des caractéristiques et classification par apprentissage automatique et profond

Soutenue le 10 /07/2021 devant le jury composé de :

Pr Ismail BOUMHIDI	***Faculté des Sciences Dhar El Mahraz – Fès***	***Président***
Pr Hassan QJIDAA	***Faculté des Sciences Dhar El Mahraz – Fès***	***Rapporteur***
Pr Abderrahmane ELYOUSFI	***Ecole Nationale des Sciences Appliquées- Agadir***	***Rapporteur***
Pr Badraddine AGHOUTANE	***Faculté des Sciences – Meknès***	***Rapporteur***
Pr Hakim EL FADILI	***Ecole Nationale des Sciences Appliquées- Fès***	***Examinateur***
Pr Ali YAHYAOUY	***Faculté des Sciences Dhar El Mahraz – Fès***	***Examinateur***
Pr Abdellah AARAB	***Faculté des Sciences Dhar El Mahraz – Fès***	***Directeur de thèse***
Pr My Abdelouahed SABRI	***Faculté des Sciences Dhar El Mahraz – Fès***	***Co-directeur de thèse***

Année universitaire : 2020-2021

Remerciements

La réalisation de cette thèse a été possible grâce à **DIEU** et à l'aide de nombreuses personnes qui ont offert leur temps, leur énergie et leurs connaissances. Merci à toutes ces personnes, sans vous ce travail n'aurait pu aboutir.

- Tout d'abord, j'aimerais remercier mes deux directeurs de thèse, Professeur **Abdellah AARAB** et Professeur **My Abdelouahed SABRI**, d'avoir accepté de diriger cette thèse, qui ont initié et orienté ce travail et qui ont toujours trouvé le temps de guider et d'encourager mes activités de recherche chaque fois qu'il était nécessaire. Je saisis cette occasion pour avouer que je suis redevable envers eux pour leur idées et suggestions pertinentes. J'apprécie beaucoup leurs compétences qui ont fait de cette thèse un succès.

- Ensuite, j'aimerais remercier tous les membres du jury qui malgré leurs nombreuses occupations, ont accepté la fastidieuse tâche d'examiner ce travail. Je remercie mes rapporteurs, Professeur **Hassan QJIDAA**, Professeur **Abderrahmane ELYOUSFI** et Professeur **Badraddine AGHOUTANE**, de la qualité de leurs remarques et de leurs critiques constructives. Je les remercie de m'avoir soutenue par leur participation dans la discussion de cette thèse. Je remercie également Professeur **Ismail BOUMHIDI** d'avoir accepté de présider le jury, pour sa collaboration et pour son extrême générosité. Mes vifs remerciements aussi pour Professeur **Hakim EL FADILI** et Professeur **Ali YAHYAOUY** pour votre soutien, votre disponibilité sans faille, nos discussions fructueuses & le partage de vos savoirs.

- Ma plus grande reconnaissance et gratitude vont vers les personnes qui me sont les plus chers et qui ont eu un rôle capital dans ma réussite. J'offre de tout mon cœur mes profonds remerciements à mes **Parents M'hammed et Ouadiaa**, qui m'ont motivé et encouragé sans cesse, qui m'ont toujours poussé à l'avant et qui attendaient avec impatience que je réussisse notre rêve partagé. C'est à eux que je consacre et dédie ce travail.

- Mes remerciements n'en sont que plus forts à mes sœurs **Kaoutar et Zineb**. Vous étiez toujours à mes côtés pour me soutenir dans mes choix et m'encourager à aller encore plus loin. Grâce à vous je n'avais qu'à me soucier de réussir mes études et être à la hauteur de mes ambitions. Si je suis entrain d'écrire ces lignes aujourd'hui, c'est grâce à votre inconditionnel soutien, je ne saurais jamais vous remercier assez.

- Je ne peux passer sous silence toute ma famille et mes proches qui ont cru en moi. Je remercie les familles **FILALI, ZIZAH, AMOR, HALOUI, ALAOUI & SENHAJI** ainsi que tous mes cousins et cousines. Je remercie Dieu de vous avoir dans ma vie.

- Mes remerciements les plus sincères vont à tous mes amis (**Driss, Houssam, Zouhir, Mehdi, Nabil, Anas, Hamza, Zineb, Mariem, Salma, Hasnae…)** et bien sûr à toute personne que je n'ai pas cité ici et qui a contribué de près ou de loin à la réussite de ce travail.

- Mes remerciements vont à toutes ces personnes formidables que j'ai croisé durant ces années de thèse et qui ont fait que je sois là aujourd'hui.

Dédicace

Je dédie cette mémoire à :

Mes chers parents pour leur patience, leur amour, leur soutien et leurs encouragements.

Mes sœurs.

Ma famille.

Mes amis.

Mes professeurs.

Et À tous ceux que j'aime,

et à tous ceux qui m'aiment ...

Résumé

En imagerie médicale, l'aide au diagnostic fait intervenir plusieurs disciplines et domaines notamment le traitement d'image, la vision artificielle, la reconnaissance des formes, et l'intelligence artificielle. Dans ce contexte, nous avons proposé de nouvelles approches relatives à l'amélioration des performances de la classification des lésions cutanées. Ces nouvelles approches concernent aussi bien la segmentation, l'ingénierie des caractéristiques, ainsi que la stratégie de la classification.

La première contribution de ce travail de thèse consiste à procéder à un prétraitement par l'utilisation de la décomposition multi-échelle à base des Equations aux Dérivées Partielles pour une segmentation efficace de la lésion cutanée. La deuxième porte sur l'extraction des caractéristiques de la région d'intérêt relatives à la forme, la texture et la couleur suivie de la sélection des caractéristiques les plus pertinentes. Pour la caractérisation de la forme, de nouvelles signatures discriminantes (branches et des nœuds) du squelette de la lésion sont proposées. La troisième vise à fusionner les performances de l'apprentissage automatique et l'apprentissage profond pour proposer un modèle de classification qui soit efficace à la fois pour les petites et les grandes bases d'images. Tous les résultats des approches développées avec comparaisons sont mis en évidence et discutés.

Mots clés :

Cancer de la peau, Lésions cutanées, Segmentation, Ingénierie des caractéristiques, fusion des caractéristiques, Squelettisation, Classification, Apprentissage automatique, Apprentissage profond.

Abstract

In medical imaging, computer aided diagnosis involves several disciplines and domains including image processing, computer vision, pattern recognition, artificial intelligence. In this context, we have proposed new approaches to improve the performance of skin lesion classification. These new approaches concern segmentation, feature engineering, as well as classification strategy.

The first contribution of this thesis work consists in a pre-processing by using a multi-scale decomposition based on Partial Differential Equations for an efficient segmentation. The second is the extraction of features of the region of interest related to shape, texture and color followed by the selection of only the most relevant features. For the shape characterization, new discriminating features (branches and nodes) of the lesion skeleton are proposed. The third one aims at the fusion of the performances of machine learning and deep learning to propose an efficient classification model for both small and large image datasets. All results of the developed approaches with comparisons are highlighted and discussed.

Keywords:

Skin cancer, Skin lesions, Segmentation, Feature engineering, Feature fusion, Skeletonization, Classification, Machine learning, Deep learning.

Liste des Abréviations

A	: Asymétrie
ABCDE	: Asymétrie, Bordure, Couleur, Diamètre et Evolution
AD	: Arbre de décision
AG	: Algorithme génétique
B	: Bordure
BV	: Bonded Varition
C	: Couleur
CBC	: Carcinomes basocelulaires
CFS	: Correlation Feature Selection
CNN	: Convolutional neural network
D	: Diamètre
DAO	: Diagnostic Assisté par Ordinateur
DL	: Deep learning
E	: Evolution
EDP	: Equations dérivées partielles
EM	: Expectation Maximization
FCM	: Fuzzy C-Means
FN	: Faux négatifs
FP	: Faux positifs
GLCM	: Gray Level Co-Occurrence Matrix
HOG	: Histogramme de gradient orienté
KNN	: K plus proche voisin
LBP	: Motifs binaires locaux (local binary patterns)
ML	: Machine Learning
MSV	: Machine support vecteur
RFE	: Recursive Feature Elimination
RL	: Régression logistique
RNA	: Réseau de neurones artificiels
ROI	: Région d'intérêt
RVB	: Rouge, vert et bleu
SDAO	: Système Diagnostic Assisté par Ordinateur
TSL	: Teinte, saturation, luminosité
VN	: Vrai négatifs
VP	: Vrai positifs

Liste des figures

FIGURE I.1. EXEMPLE DE DERMATOSCOPE....19
FIGURE I.2. REGLES DE L'ABCDE....20
FIGURE I.3. FONCTIONS PRINCIPALES D'UN SYSTEME DAO....22
FIGURE I.4. TYPES DE BRUITS COURANTS : CONTOUR SOMBRE (A), POIL DE PEAU (B), GEL DERMOSCOPIQUE (C), MARQUEUR DE REGLE (D) ET MARQUEUR D'ANCRE (E)....24
FIGURE I.5. IMAGE DE LA BASE DE DONNEES PH2 AVEC MASQUE DE SEGMENTATION....31
FIGURE I.6. UN ECHANTILLON D'IMAGES DE LA BASE DE DONNEES PH2....32
FIGURE I.7. UN ECHANTILLON D'IMAGES DE LA BASE DE DONNEES ISIC2017....32
FIGURE I.8. UN ECHANTILLON D'IMAGES DE LA BASE DE DONNEES ATLAS DERMOSCOPY....33
FIGURE II.1. RESULTATS DE LA DECOMPOSITION....38
FIGURE II.2. RESULTATS DE LA SEGMENTATION PAR APPLICATION DE L'ALGORITHME OTSU....39
FIGURE II.3. RESULTATS DE LA SEGMENTATION PAR APPLICATION DE L'ALGORITHME CONTOUR ACTIF .40
FIGURE II.4. RESULTATS DE LA SEGMENTATION PAR APPLICATION DE L'ALGORITHME SPLIT AND MERGE40
FIGURE II.5. RESULTATS DE LA SEGMENTATION PAR APPLICATION DE L'ALGORITHME K-MEANS....41
FIGURE II.6. RESULTATS DE LA SEGMENTATION PAR APPLICATION DE L'ALGORITHME FCM....42
FIGURE II.7. RESULTATS DE LA SEGMENTATION PAR APPLICATION DE L'ALGORITHME EM....43
FIGURE II.8. DIAGRAMME DES ETAPES DE CARACTERISATION DES IMAGES DERMOSCOPIQUES....45
FIGURE II.9. MASQUE ET SQUELETTE DES LESIONS MELANOME ET NON MELANOME....47
FIGURE II.10. CARACTERISATION DU SQUELETTE DE L'IMAGE DE LA LESION : (A) MASQUE DE LA LESION (B) SQUELETTE ; ROND BLEU TERMINAISON, ROND ROUGE BIFURCATION....48
FIGURE II.11. DROITES DE SYMETRIE EN BLEU (A) Y=-0.1634X+392.7798 COEFFICIENT DE CORRELATION =-0.1267 (B) Y=-0.0983X+240.8707 COEFFICIENT DE CORRELATION=-0.1267....48
FIGURE II.12. CALCUL DU NOMBRE POUR LBP....51
FIGURE II.13. PROCEDURE GENERALE D'UN ALGORITHME DE SELECTION DE CARACTERISTIQUES [CHO 11] 56
FIGURE II.14. PROCEDURE DU MODEL "FILTRE" [CHO 11]....57
FIGURE II.15. PROCEDURE DU WRAPPER [OLI 14]....58
FIGURE II.16. DIFFERENTES ECHELLES DU FILTRE DE GABOR....63
FIGURE III.1. EXEMPLE D'ARBRE DE DECISION....71
FIGURE III.2. VISUALISATION D'UNE MACHINE A VECTEUR DE SUPPORT DIVISANT UN ENSEMBLE DE DONNEES EN DEUX CLASSES, EN UTILISANT DEUX SEPARATIONS LINEAIRES DIFFERENTES.....73
FIGURE III.3. EXEMPLE D'UN RESEAU DE NEURONE ARTIFICIEL....76
FIGURE III.4. COMPARAISON DES 4 DIFFERENTS ALGORITHMES DE CLASSIFICATION....78
FIGURE IV.1. ARCHITECTURE GENERALE DU CNN....87
FIGURE IV.2. ARCHITECTURE DE LENET [LEC 05]....90
FIGURE IV.3. ARCHITECTURE D'ALEXNET [KRI 07]....91
FIGURE IV.4. ARCHITECTURE DU VGGNET [SIM 15]....92
FIGURE IV.5. ARCHITECTURE DU GOOGLENET [SZE 14]....93
FIGURE IV.6. ARCHITECTURE DU RESNET [HE 16]....94
FIGURE IV.7. APPROCHE PROPOSEE POUR L'ENTRAINEMENT DES IMAGES DE DERMOTALOGIE EN UTILISANT LA TEXTURE COMME ENTREE AU CNN....95
FIGURE IV.8. ARCHITECTURE DE L'APPRENTISSAGE PROFOND ADOPTEE....96
FIGURE IV.9. APPROCHE PROPOSEE BASEE SUR LE SQUELETTE....97
FIGURE IV.10. APPROCHE PROPOSEE DE FUSION DE ML ET DL POUR LA CLASSIFICATION DES LESIONS CUTANEES 100

Liste des tableaux

TABLEAU I.1. TRAVAUX ANTERIEURS 28
TABLEAU. II.1. ALGORITHMES DE SEGMENTATION 38
TABLEAU. II.2. SENSITIVITE ET SPECIFICITE POUR TOUTE LA BASE DE DONNEE SANS ET AVEC PRETRAITEMENT 44
TABLEAU. II.3. RESULTAT DE CLASSIFICATION 63
TABLEAU. II.4. PRECISION DES DIFFERENTES CARACTERISTIQUES 64
TABLEAU. II.5. CARACTERISTIQUES SELECTIONNEES AVEC LES 4 DIFFERENTS ALGORITHMES DE SELECTION 65
TABLEAU. II.6. RESULTAT DE LA SELECTION DE CARACTERISTIQUES 66
TABLEAU. II.7. MATRICE DE CONFUSION 66
TABLEAU. II.8. ETUDE COMPARATIVE DE LA CLASSIFICATION UTILISANT LA BASE DE DONNEES PH2 UTILISANT DIFFERENTS ALGORITHMES DE LA LITERATURE 67
TABLEAU III.1. SENSITIVITE, SPECIFICITE ET EXACTITUDE UTILISANT LES 4 ALGORITHMES DE CLASSIFICATION 77
TABLEAU III.2. MATRICE DE CONFUSION DES MEILLEURS CLASSIFICATEURS 79
TABLEAU III.3. SENSITIVITE, SPECIFICITE ET EXACTITUDE DES DIFFERENTS ALGORITHMES DE CLASSIFICATION 82
TABLEAU III.4. SENSITIVITE, SPECIFICITE ET EXACTITUDE UTILISANT LES 4 ALGORITHMES DE CLASSIFICATION AINSI QUE LE VOTE MAJORITAIRE 83
TABLEAU III.5. RESULTATS DE CLASSIFICATION DE NOTRE APPROCHE EN COMPARAISON AVEC DEUX APPROCHES DE LA LITTERATURE. 83
TABLEAU IV. 1. RESULTAT DE L'APPRENTISAGE PROFOND UTILISANT LES COMPOSANTES OBJETS, TEXTURES, REGIONS D'INTERET ET SQUELETTES. 98
TABLEAU IV. 2. RESULTAT EN TERME DE TEMPS D'EXECUTION DE L'APPROCHE PROPOSEE 99
TABLEAU IV. 3. RESULTAT DE CLASSIFICATION POUR LES DIFFERENTES CARACTERTISTIQUES 102
TABLEAU IV. 4. SELECTION DES CARACTERISTIQUES EN UTILISANT LE GENETIQUE ALGORITHME 103
TABLEAU IV. 5: RESULTAT DE LA CLASSIFICATION EN UTILISANT LA SELECTION DES CARACTERISTIQUES SUR LES DEUX BASES D'IMAGES PH2 ET ISIC 103
TABLEAU IV. 6. LA MATRICE DE CONFUSION DE NOTRE MODELE DE CLASSIFICATION POUR LES DEUX BASES D'IMAGES PH2 ET ISIC 104
TABLEAU IV. 7. RESULTATS DE L'APPROCHE PROPOSEE EN COMPARAISON AVEC DES APPROCHES RECENTES DE LA LITTERATURE POUR LA BASE D'IMAGES PH2 [FIL 20B] 104
TABLEAU IV. 8. RESULTATS DE L'APPROCHE PROPOSEE EN COMPARAISON AVEC DES APPROCHES RECENTES DE LA LITTERATURE POUR LA BASE D'IMAGES ISIC 105

Table des matières

REMERCIEMENTS ..... **I**

DEDICACE ..... **II**

RESUME ..... **III**

ABSTRACT ..... **IV**

LISTE DES ABREVIATIONS ..... **V**

LISTE DES FIGURES ..... **VI**

LISTE DES TABLEAUX ..... **VII**

INTRODUCTION GENERALE **11**

CHAPITRE I : GENERALITES SUR LES SYSTEMES D'AIDE AU DIAGNOSTIC **15**

I.1. INTRODUCTION **16**

I.2. CONTEXTE MEDICAL **16**

I.2.1. STRUCTURE DE LA PEAU 16
I.2.2. TYPES DE CANCER DE LA PEAU 16
I.2.3. FACTEURS DE RISQUE 18
I.2.4. LA DERMOSCOPIE 18
I.2.5. EXAMEN ET DIAGNOSTIC 19

I.3. FONCTIONS PRINCIPALES DES SYSTEMES DE DIAGNOSTIC ASSISTE PAR ORDINATEUR 21

I.3.1. ACQUISITION D'IMAGES 22
I.3.2. LE PRETRAITEMENT 24
I.3.3. SEGMENTATION 24
I.3.4. EXTRACTION DES CARACTERISTIQUES 26
I.3.5. SELECTION DES CARACTERISTIQUES 27
I.3.6. CLASSIFICATION 27
I.3.7. TRAVAUX ANTERIEURS 27

I.4. ÉVALUATION D'UN SYSTEME D'AIDE AU DIAGNOSTIC MEDICAL **29**

I.4.1. LES CRITERES D'EVALUATION 30
I.4.2. BASES DE DONNEES 31

I.5. CONCLUSION **33**

CHAPITRE II: CONTRIBUTIONS A LA SEGMENTATION ET LA CARACTERISATION DES IMAGES DERMOSCOPIQUE **34**

II.1. INTRODUCTION **35**

II.2. APPROCHES DE SEGMENTATION **35**

II.2.1. MODELE DE DECOMPOSITION VARIATIONNEL 36
II.2.2. ÉTUDE DES PERFORMANCES 38
II.2.2.1. Algorithmes de segmentation *39*
II.2.2.2. Résultats des simulations *43*

II.3. L'INGENIERIE DE CARACTERISTIQUES **44**

II.3.1. CHOIX DES CARACTERISTIQUES 45
II.3.1.1. Caractéristiques de forme *45*
II.3.1.2. Caractéristiques de couleur *48*
II.3.1.3. Caractéristiques de texture *49*
II.3.1.4. Mise en échelle des caractéristiques *54*
II.3.2. INGENIERIE DES CARACTERISTIQUES 55

II.3.2.1. Sélection de caractéristiques *55*
II.3.2.2. Procédures d'évaluation *56*
II.3.2.3. Procédure de sélection *60*
II.3.3. EVALUATION DES PERFORMANCES 62
II.3.3.1. Etude préliminaire *63*
II.3.3.2. Résultats des simulations *64*

II.4. CONCLUSION 67

CHAPITRE III : CLASSIFICATION DES LESIONS CUTANEES BASEE SUR L'APPRENTISSAGE AUTOMATIQUE 69

III.1 INTRODUCTION 70

III.2 ALGORITHMES DE CLASSIFICATION 70

III.2.1 REGRESSION LOGISTIQUE 70
III.2.2 ARBRE DE DECISION 71
III.2.3 RESEAUX BAYESIENS 72
III.2.4 MACHINES A VECTEURS DE SUPPORT 73
III.2.5 APPRENTISSAGE BASE SUR LES INSTANCES 74
III.2.6 RESEAU DE NEURONES ARTIFICIELS 74
III.2.7 RESULTATS DE SIMULATION 76

III.3 APPRENTISSAGE ENSEMBLISTE ADOPTE POUR LA CLASSIFICATION DES LESIONS CUTANEES 79

III.3.1 LE VOTE 80
III.3.2 BOOSTING 80
III.3.3 BAGGING 81
III.3.4 RESULTATS DE SIMULATION 82

III.4 CONCLUSION 83

CHAPITRE IV : CLASSIFICATION DES LESIONS CUTANEES BASEE SUR L'APPRENTISSAGE PROFOND 85

IV.1. INTRODUCTION 86

IV.2. LES ARCHITECTURES D'APPRENTISSAGE PROFOND 86

IV.2.1. CNN 86
IV.2.1.1. Couche convolutionnelle *88*
IV.2.1.2. Couche de sous-échantillonnage « Sub-sampling Layer » *88*
IV.2.1.3. Couche de classification *88*
IV.2.2. LENET 89
IV.2.3. ALEXNET 90
IV.2.4. ZFNET / CLARIFAI 91
IV.2.5. NETWORK IN NETWORK (NIN) 91
IV.2.6. VGGNET 92
IV.2.7. GOOGLENET 92
IV.2.8. RESEAU DES RESIDUS (RESNET) 93
IV.2.9. DENSELY CONNECTED NETWORK (DENSENET) 94

IV.3. APPRENTISSAGE PROFOND BASE SUR LA TEXTURE ET DU SQUELETTE DES LESIONS CUTANEES 94

IV.3.1. APPRENTISSAGE PROFOND BASE SUR DES COMPOSANTES MULTI-ECHELLES 94
IV.3.2. APPRENTISSAGE PROFOND BASE SUR LE SQUELETTE DES LESIONS 96
IV.3.3. RESULTATS DE SIMULATION 97

IV.4. FUSION DE L'APPRENTISSAGE PROFOND ET EXTRACTION MANUELLE DES CARACTERISTIQUES 99

IV.4.1. EXTRACTION DES CARACTERISTIQUES 100
IV.4.2. SELECTION DE CARACTERISTIQUES 102

IV.4.3. FUSION DES CARACTERISTIQUES 103
IV.5. CONCLUSION 106
CONCLUSION GENERALE ET PERSPECTIVES 107
BIBLIOGRAPHIES 111
LISTE DES CONTRIBUTIONS 123

Introduction générale

Ce travail s'inscrit dans le cadre de la détection assistée par ordinateur du cancer de la peau et plus particulièrement le mélanome. Le mélanome, est considéré être le plus dangereux selon le rapport de l'Organisation Mondiale de la Santé (environ 70 230 personnes en meurent chaque année) [SIE 20]. L'origine de ce cancer se situe dans l'épiderme de la peau et les couches dermiques. Il se forme à partir de l'accumulation de pigments de mélanine et de sa propagation vers la couche externe de la peau. L'exposition directe de la peau au soleil est le principal facteur de croissance des cellules basales. Ce type de cancer est complètement curable à un stade précoce du diagnostic. Par contre à un state avancé, son traitement nécessite une exérèse, une chimiothérapie et ou une radiothérapie.

Dès les années 60 les dermatologues utilisaient des dermoscopes, outils non invasifs adéquats pour l'observation des lésions cutanées et ainsi évaluer les écarts dans les troubles de la pigmentation de la peau. Depuis cette période, et au fil du temps des versions améliorées sur le plan des performances d'agrandissement, de suppression des artefacts et d'observation en profondeur ont été élaborées. Actuellement, avec le développement sans cesse croissant de la technologie, on assiste à des versions numériques du dermatoscope avec la capacité de recevoir et de stocker les images de la peau. Le diagnostic assisté par ordinateur permet de mesurer un ensemble de caractéristiques dans les images dermoscopiques et apporte une contribution significative dans le diagnostic du cancer de la peau à son stade précoce.

Malgré les améliorations apportées aux systèmes actuels de diagnostic assisté par ordinateur (DAO) au fil des ans, ces systèmes sont encore loin de la perfection et nécessitent davantage de développements pour améliorer le diagnostic du mélanome et des défis restent à relever à toutes les étapes de traitement et d'analyse des images dermoscopiques. Tout d'abord, une segmentation précise, permet d'améliorer dans un premier temps la détection des lésions suspectes, et ensuite l'extraction des caractéristiques les plus pertinentes mènent à une bonne classification de ces lésions en malignes et bénignes.

Une compréhension approfondie des diverses caractéristiques dermoscopiques liées au cancer, y compris les modèles individuels d'une lésion tels que la couleur, la bordure et la symétrie, sont requisent afin de sélectionner les méthodes appropriées pour implémenter le système de DAO. Afin d'atteindre un haut niveau d'efficacité pour le diagnostic automatisé, il est important d'utiliser des approches de traitement d'image et d'apprentissage automatique efficaces dans les principales étapes du système de DAO. Il est important de procéder à une comparaison de toutes les méthodes proposées sur des ensembles d'images dermoscopiques disponibles gratuitement accompagnées de la vérité terrain du diagnostic rapporté par plusieurs dermatologues.

Objectif

L'objectif principal de cette thèse est d'améliorer la détection et la classification des mélanomes. Pour atteindre cet objectif, le travail de thèse a été orienté dans les directions suivantes :

- Etablir une méthode de prétraitement adaptée aux lésions cutanées.
- Développer une méthode d'extraction des caractéristiques basée sur l'ingénierie des caractéristiques.
- Développer une méthode basée sur la fusion des caractéristiques issue de l'apprentissage profond et celles extraites manuellement.

Hypothèse de recherche

Pour atteindre nos objectifs de recherche, les hypothèses de recherche suivantes sont formulées :

- La décomposition de l'image au préalable à l'aide des Equations différentielle partielle (EDP) contribuerait à une bonne segmentation de l'image dermscopique de la lésion cutanée,
- La squelettisation de la région d'intérêt pourrait fournir une description des lésions de la peau pigmentée en termes de forme et ainsi améliorer le taux de classification du cancer de peau,
- L'ingénierie de caractéristiques permettrait de réduire la dimensionnalité des caractéristiques utilisées pour retenir les plus pertinentes afin d'améliorer encore le taux de classification,
- Fusionner les caractéristiques issues de différentes architecture Deep Learning et celles extraites manuellement afin de concevoir un modèle de classification très puissant.

Portée des travaux de recherche

L'objectif de ce travail est d'aider et d'améliorer le diagnostic assisté par ordinateur basé sur des méthodes de traitement d'images. Le travail élaboré dans ce document porte sur trois principales contributions au niveau de la segmentation, l'extraction et sélection des caractéristiques, et la classification. La première consiste à procéder à une décomposition de l'image à base d'un model d'Aujul issu des équations dérivées partielles pour une segmentation efficace de la lésion cutanée. La deuxième porte sur l'extraction des caractéristiques de la région d'intérêt relatives à la forme, la texture et la couleur suivie de la sélection des caractéristiques les plus pertinentes. Pour la caractérisation de la forme, de nouvelles signatures discriminantes (branches et des nœuds) du squelette de la lésion sont proposées. La troisième vise à utiliser

l'apprentissage profond avec différentes architectures pour extraire et classer le cancer de la peau. Tous les résultats des approches développées avec comparaisons sont mis en évidence et discutés.

Organisation du document

Cette thèse contient un arrière-plan et un état de l'art sur la segmentation et classification du cancer de peau, un ensemble d'approche de l'extraction des caractéristiques ainsi que de l'apprentissage profond. On outre, le reste de cette thèse est organisé comme suit :

Chapitre 1 : Présente une brève description de la cancérogenèse et de la procédure de l'examen clinique du cancer de la peau. Par la suite, la méthodologie de conception des systèmes DAO ainsi que les étapes nécessaires à leurs réalisations.

Chapitre 2 : Consacré à l'ensemble des méthodes de segmentation classique employés dans la diagnostique médicale, ainsi que les nouvelles approches proposées de segmentation et de caractérisation des images dermoscopique, par la suite nous citons l'ensembles des outils artificiels réservés à l'extraction et la sélection des caractéristiques.

Chapitre 3 : Présente dans un premier temps une étude comparative entre les meilleurs algorithmes de classification utilisés dans la classification des lésions cutanées. La deuxième partie est consacrée à la classification ensembliste.

Chapitre 4 : Consacré à la détection et la classification des lésions cutanées à l'aide d'un réseau neuronal convolutif (Convolutional Neural Network, CNN) dont l'entrée est l'image « texture » issue de la décomposition, puis l'image du squelette des lésions au lieu des images entières. Ainsi, nous présentons l'approche proposée de classification des lésions cutanées basée sur une fusion de caractéristiques manuelle (Handcrafted features) et des caractéristiques extraites des architectures Deep Learning les plus performantes.

Nous clôturons notre rapport avec une conclusion générale, où nous résumons les travaux réalisés et cités dans les quatre chapitres précédents.

Chapitre I :
Généralités sur les systèmes d'aide au diagnostic

I.1. Introduction

Au cours des dernières décennies, l'avènement des nouvelles technologies a contribué au perfectionnement des dispositifs d'acquisition des images médicales pour les différentes modalités à travers la miniaturisation et l'automatisation, et ainsi l'imagerie médicale est devenue indispensable dans le diagnostic et la thérapie des maladies. Les images médicales sont actuellement disponibles en quantité abondante, de nouvelles méthodes sont requises pour mieux extraire d'une manière efficace les informations de ces images à travers une analyse d'images fondée sur l'apprentissage profond et qui a conduit récemment à des avancées significatives dans le dépistage précoce de pathologies, dans l'aide au diagnostic, ou dans la segmentation de structures anatomiques.

Avant de procéder à une description des fonctions des systèmes d'aide à la décision (DAO), nous avons jugé utile de présenter la portée médicale de ce travail à travers une brève description de la cancérogenèse et de la procédure de l'examen clinique. Par la suite, la méthodologie de conception de ces systèmes ainsi que les étapes nécessaires à leurs réalisations sont présentées.

I.2. Contexte médical

I.2.1. Structure de la peau

La peau est un organe multifonctions, qui permet la protection de plusieurs agressions extérieur (chocs, pollution, microbes, rayons ultraviolets…), la régulation thermique, la synthèse hormonale (vitamine D, et différentes hormones), ainsi qu'une fonction immunitaire. La peau est constituée de trois couches distinctes : l'épiderme, le derme et l'hypoderme.

- **L'épiderme** est la couche supérieure, qui est en contact direct avec le milieu extérieur assurant des propriétés comme la pigmentation, la perception, la protection, la régulation, et la régénération de notre organisme.
- **Le derme** est la partie résistante de la peau, très riche en fibre qui contient des vaisseaux sanguins, des glandes sudoripares, des follicules pileux, des terminaisons nerveuses sensibles à la pression ou à la température ou à la douleur.
- **L'hypoderme** c'est la couche la plus profonde. C'est un tissu de soutien souple et déformable dont le rôle est de servir d'interface entre la peau et les organes qu'elle recouvre (muscles, os…). Il isole le corps en préservant sa chaleur, absorbe les chocs pour protéger les tissus sous-jacents, et constitue une réserve d'énergie.

I.2.2. Types de cancer de la peau

Le cancer de la peau comme tout autre cancer se caractérise par l'envahissement progressif de l'organe d'origine, puis de l'organisme entier, par des cellules devenues peu sensibles ou

insensibles aux mécanismes d'homéostasie tissulaire et ayant acquis une grande capacité de prolifération (*World Health Organization*). On distingue essentiellement deux types de cancer : le carcinome et le mélanome.

Le premier type appelé carcinome est le plus fréquent des cancers de la peau. Parmi les carcinomes cutanés, on distingue trois groupes :

1. Les carcinomes basocellulaires (CBC) qui se développent à partir de la couche profonde de l'épiderme n'ont qu'une malignité locale et, en général, ne produisent pas de métastases.
2. Les carcinomes spinocellulaires se développent à partir des couches plus superficielles de l'épiderme et peuvent engendrer des métastases dans les ganglions ou dans des organes distants. Ils peuvent également toucher les muqueuses comme le rebord des lèvres ou la sphère génitale.
3. Les carcinomes annexiels, sont généralement rares, et se développent à partir des annexes de la peau comme les glandes sudorales, les follicules pileux ou les glandes sébacées.

Le second type est le mélanome qui est une tumeur maligne des cellules (mélanocytes) qui produisent la mélanine qui colore la peau et la protège des méfaits des rayons ultraviolets. On distingue quatre types de mélanomes :

1. Le mélanome superficiel extensif, qui provient d'un grain de beauté ou toute autre substance et constitue la majorité des mélanomes. Il se présente comme une tache ou un grain de beauté qui s'étend, prend une forme irrégulière, avec une couleur inhomogène.
2. Le mélanome nodulaire est un bourgeonnement ferme, saillant, de couleur noire ou parfois non coloré, pouvant s'ulcérer, se recouvrir d'une croûte, suinter ou saigner.
3. Le mélanome de Dubreuilh qui est une tache pigmentée, inhomogène, allant du noir au marron foncé et qui s'étend très lentement sur les zones exposées au soleil chez le sujet âgé et ressemble à une tache de vieillesse.
4. Le mélanome acral-lentigineux est observé sur les paumes ou les plantes de pieds (tache brune ou noire aux contours irréguliers), au niveau des ongles (bande noire supérieure à 6 millimètres de large, pigmentation irrégulière).

Une des particularités du mélanome est son aptitude à envahir les tissus au-delà de la peau (muscles, ganglions lymphatiques avoisinants) et à aller se greffer dans les organes distants sous forme de métastases.

I.2.3. Facteurs de risque

La pigmentation de la peau et la réaction suite à l'exposition solaire constituent les principaux facteurs de risque d'apparition d'un mélanome, toutefois, les rayons ultraviolets provenant du soleil peuvent provoquer des anomalies au niveau du noyau des cellules de l'épiderme.

Le risque peut augmenter en fonction de la durée d'exposition au soleil et de l'intensité du rayonnement. Les effets destructeurs du rayonnement ultraviolet s'accumulent au cours du temps. L'exposition au soleil pendant l'enfance peut aussi jouer un rôle déterminant dans la manifestation de ces cancers à l'âge adulte.

Les personnes ayant des membres de leur famille atteinte peuvent présenter un risque supplémentaire que l'on estime à 10% de mélanome. Les maladies génétiques qui affectent la peau peuvent aussi augmenter le risque d'albinisme (une anomalie d'origine congénitale caractérisée par une absence de pigmentation entraîne une sensibilité accrue de la peau au rayonnement ultraviolet).

I.2.4. La Dermoscopie

En développement depuis une trentaine d'années, la dermoscopie est une technique de microscopie de surface qui permet l'observation des structures pigmentaires internes de l'épiderme, de la jonction dermo-épidermique et des premières couches du derme. Elle utilise un équipement optique simple, appelé dermoscope, constitué d'une lentille grossissante et d'une source de lumière. Son principe de fonctionnement est basé sur l'absorption de la lumière, produite par le dermoscope, par les différents pigments de la peau. La lumière peut parvenir jusqu'à la jonction dermo-épidermique et même au-delà si la peau du patient est peu pigmentée. L'image obtenue résulte de la distribution et de l'architecture des pigments de la peau dans l'épiderme et le derme.

La démoscopie a permis de révéler des signes invisibles à l'œil nu et a jeté les bases d'une nouvelle analyse. La recherche a pour but d'aboutir à une bonne précision du diagnostic clinique de manière à augmenter la sensibilité du diagnostic tout en essayant d'augmenter la spécificité afin de diminuer le nombre d'exérèses inutiles [MEN 96]. L'usage du dermatoscope, pour le diagnostic du mélanome précoce, nécessite cependant une bonne formation à l'analyse des images dermatoscopiques. Les critères morphologiques pris en compte pour l'analyse de l'image dermoscopique sont: l'aspect général de la lésion (couleur et forme), la texture du réseau pigmentaire, les caractéristiques morphologiques du contour de la lésion (asymétrie), la présence d'éléments spécifiques (pseudopodes, stries radiales).



Figure I.1. Exemple de dermatoscope

Le dermoscope n'a pas connu d'évolution technologique figure I.1. Ce sont les systèmes de capture et de traitement d'image associés au dermoscope qui sont actuellement en évolution. L'appareil de dermoscopie digitale se compose d'un puissant dermoscope à main fixé à une caméra numérique elle-même reliée à un écran, qui affiche l'image en temps réel sur un ordinateur muni de logiciels permettant la capture et le stockage des images, qui peuvent facilement être récupérées pour évaluation ou comparaison dans le temps. Le grossissement optique est plus important de 15 à 140 fois, en fonction des appareils. Certains appareils sont couplés à des méthodes de diagnostic assistées par ordinateur.

I.2.5. Examen et diagnostic

L'examen clinique a pour objectif d'identifier toute lésion cutanée pouvant évoquer un mélanome et toute lésion cutanée pouvant être susceptible d'évoluer vers un mélanome. Un examen doit être sensible pour ne pas méconnaître de lésions suspectes. Il doit être le plus spécifique possible pour ne pas alerter à tort le patient et pratiquer l'exérèse inutile de lésions bénignes. Pour améliorer le diagnostic précoce et diminuer ainsi le nombre de faux positifs (correspondant aux nombres d'exérèses inutiles), d'autres techniques telle que la dermatoscopie sont venues compléter les résultats de l'examen clinique et pour mieux caractériser ces lésions.

Les éléments pris en compte sont principalement le nombre de couleur et la forme des lésions, leur disposition, leur topographie, leur distribution et leur étendue. Plusieurs critères cliniques peuvent faire suspecter la malignité. L'association de ces critères permet de définir

des règles de décision. La démarche analytique visuelle s'appuie généralement sur trois méthodes : deux méthodes analytiques visuelles (règle dermoscopique ABCDE, liste révisée des 7 points du groupe de Glasgow) et une méthode cognitive la Règle ABCDE ou la Liste révisée des 7 points du groupe de Glasgow.

La Règle ABCDE a été introduite et décrite par [FRI 85] en 1985 et modifiée par (Thomas, L.; Tranchand, P.; Berard, 1998). L'acronyme ABCDE signifie : A = asymétrie ; B = bordure ; C = couleur ; D = diamètre ; E = évolutivité voir figure I.2.

- Asymétrie : Un grain de beauté bénigne asymétrique est un signe d'avertissement pour le mélanome. Une lésion asymétrique est susceptible d'être un mélanome.
- Bordure : Les limites d'un mélanome précoce ont tendance à être inégales. Les lésions ont des bords irréguliers, encochés, polycycliques, nettement délimités par rapport à la peau environnante. Les bords peuvent être festonnés ou dentelés.
- Couleur : La plupart des grains de beauté bénins sont tous d'une seule couleur et souvent d'une seule nuance de brun. Le fait d'avoir une variété de couleur inhomogène, toutes les nuances chromatiques de la mélanine (du brun clair au noir foncé) est un autre signal d'alarme. Un mélanome peut aussi devenir rouge, blanc ou bleu.
- Diamètre : Des zones blanches où le pigment a disparu, des zones rouges inflammatoires ou des zones cicatricielles qui apparaissent bleutées peuvent également être observées ; de diamètre > 6 mm; Les grains de beauté bénins ont généralement un diamètre plus petit que les grains de beauté malins.
- Evolutivité : Les grains de beauté communs et bénins se ressemblent au fil du temps. Tout changement de taille, de forme, de couleur, d'élévation ou d'une autre caractéristique, ou tout nouveau symptôme tel que saignement, démangeaisons ou croûte, indique un danger.

	Asymétrie	*Bordure*	*Couleur*	*Diamètre*	*Evolutivité*
Non-mélanome					
Mélanome					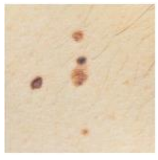

Figure I.2. Règles de l'ABCDE

Une règle, dérivée de la règle ABCDE, dite « règle des 7 points du groupe de Glasgow » a été publiée en 1989 par Mackie [MAC 89]. Cette règle prend en compte 3 critères majeurs, 4 critères mineurs, et donne une place prépondérante au concept d'évolution.

- Les critères majeurs sont les suivants : le changement de taille dans une lésion connue ou croissance d'une nouvelle lésion ; le changement dans la forme de la lésion ; et le changement dans la couleur de la lésion.
- Les critères mineurs sont : le plus grand diamètre > 7 mm ; l'inflammation ; la présence d'une ulcération ou d'un saignement ; et le changement dans la sensibilité de la lésion.

La reconnaissance globale de l'image fait appel à un processus cognitif spontané qui permet à partir d'une formation par l'image (photos de nævus communs et/ou atypiques et photos de mélanomes) d'élaborer un modèle de reconnaissance visuelle. Le principe part du postulat que chez un sujet donné, les nævus ont un aspect clinique (forme, couleur, épaisseur) homogène. De ce fait, une lésion mélanocytaire sera considérée comme suspecte si elle est cliniquement différente des autres nævus du patient.

La performance de la démoscopie est étroitement liée à l'algorithme utilisé dans l'analyse. Des études montrent que l'utilisation de la dermoscopie permettrait d'éviter l'excision de presque la moitié des tumeurs bénignes. La dermoscopie a une sensibilité et une spécificité variables, significativement et supérieures à celles de l'examen clinique surtout lorsqu'il était réalisé par un médecin formé à l'usage de cette technique. En ce qui concerne le diagnostic différentiel entre un mélanome et un nævus atypique, la dermoscopie n'apporte pas de certitude diagnostique suffisante pour éviter une exérèse de contrôle. Elle ne modifie donc pas, dans ce cas particulier, la pratique thérapeutique. Le diagnostic des tumeurs pigmentées nodulaires ou purement dermiques demeure difficile avec la dermoscopie dont le domaine de visualisation s'étend essentiellement jusqu'au derme papillaire.

Le traitement consiste en une intervention chirurgicale qui enlève la lésion (exérèse) et une zone de peau saine tout autour en tant que marge de sécurité. Une surveillance prolongée et régulière s'impose ensuite pour repérer une éventuelle récidive, l'apparition d'une autre lésion ou le développement de métastase. Dans certains cas, le traitement peut également faire appel à l'immunothérapie, à la chimiothérapie ou à la radiothérapie.

I.3. Fonctions principales des systèmes de Diagnostic Assisté par Ordinateur

Des systèmes de Diagnostic Assisté par Ordinateur (DAO) ont été développés dans plusieurs domaines de l'imagerie médicale. L'objectif des systèmes de (DAO) est de donner un résultat par ordinateur comme deuxième option afin d'aider les médecins à faire une interprétation pour améliorer la précision du diagnostic et réduire le temps de lecture des images [DOI 07].

Dans cette section, nous présentons sommairement quelques principales fonctions de traitement d'un système d'aide au diagnostic à savoir: l'acquisition, le prétraitement, la segmentation, l'extraction des caractéristiques et l'identification des types de lésions. La figure I.3 illustre les étapes de système de détection.

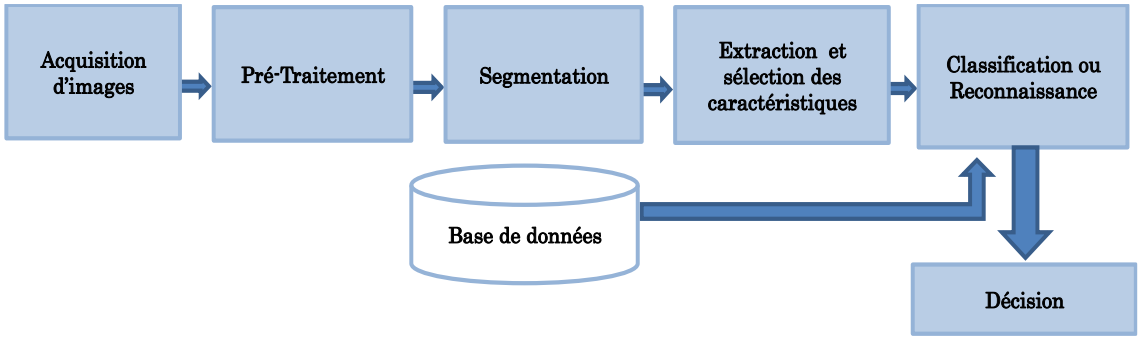

Figure I.3. Fonctions principales d'un système DAO

Après l'acquisition de l'image issue de la modalité utilisée, tous ces systèmes commencent par une phase de prétraitement de l'image de la lésion cutanée suivie du processus de segmentation qui consiste généralement à extraire la région d'intérêt du reste de l'image représentant la partie saine de la peau. L'extraction de la région de la lésion de la peau saine demeure une tâche critique.

Le prétraitement et la segmentation de l'image de lésion sont des tâches de traitement d'images de bas niveau. La classification d'objets, étape cruciale d'un système intelligent d'aide au diagnostic, consiste à identifier les types de lésion existent distinctement dans une image. La reconnaissance du type de lésions (maligne et non maligne) et le traitement de données du patient est considérée comme une tâche de vision de haut niveau.

Pour chaque niveau, de nombreux algorithmes existent et sont le sujet d'une recherche active. L'élaboration d'une application combinant des algorithmes de différents niveaux reste un problème difficile. Cela devrait être facile d'adapter l'application, lorsque l'environnement change, ou quand elle est appliquée dans différentes modalités d'acquisition.

I.3.1. Acquisition d'images

Il existe différents types de procédés d'acquisition d'images pour le dépistage des lésions cutanées : la photographie, la dermoscopie, l'imagerie multi-spectrale, le diagnostic amélioré par laser, la tomographie par cohérence optique, l'imagerie par ultrasons et l'imagerie par résonance magnétique. Pour chacune de ces méthodes ayant ses propres avantages et limites [MAS 13].

- Photographie : Elle est utilisée surtout pour suivre l'évolution des lésions suspectes chez les personnes présentant un haut risque de développer un cancer de la peau [MAR 03] à travers une comparaison des photos hautes définitions locales prises lors des visites médicales. Ainsi, les lésions ayant évoluées de façon suspecte peuvent alors être identifiées et analysées par une biopsie.
- Microscopie confocale à balayage laser : Cette technique permet d'obtenir des images tridimensionnelles (3D) de l'épiderme avec une bonne résolution permettant à imager d'une manière plus fine les structures cellulaires des couches superficielles de

l'épiderme. Elle peut fournir plus d'informations sur les caractéristiques d'une lésion mais demeure complexe et très coûteuse pour des applications cliniques quotidiennes [OLI 04][MOG 07].

- Tomographie optique cohérente : Cette technique permet de générer des images en coupe des tissus cutanés. Ces images sont générées en mesurant leurs réflexions optiques et en utilisant des techniques d'interférométrie pour obtenir de bonnes résolutions [MAR 03]. Sa complexité, son coût élevé et le temps requis pour effectuer un examen clinique, rend cette technique non applicable pour les examens dermatologiques quotidiens [OLI 04].
- Echographie à haute fréquence : L'imagerie par ultrasons haute fréquence est une technique biomédicale qui permet de visualiser les structures internes des tissus en mesurant leurs réflexions acoustiques. Son principe de fonctionnement consiste à placer une sonde dotée d'un transducteur ultrasonore sur la région d'intérêt. Appliquée en dermatologie, cette technique ne conduit pas à une différenciation entre le mélanome et les lésions bénignes; tous les deux apparaissent sur les images échographiques comme des lésions hypéchogènes [OLI 04]. Cependant, à haute fréquence elle peut être utilisée pour une évaluation de l'épaisseur et de l'étendue de lésions cutanées [MOG 07].
- Spectroscopie d'impédance électrique : Cette technique repose sur le principe de la conductivité des tissus biologiques qui varie de façon spécifique en fonction de la fréquence [HUA 11] . La conductivité électrique des lésions cutanées cancéreuses diffère de celle de la peau saine en raison de mutations génétiques qui génèrent des anomalies au niveau des structures cellulaires. De plus, contrairement aux cellules normales, qui sont bien organisées en couche et maintiennent des jonctions protéiques fortes avec les cellules adjacentes, les cellules cancéreuses ont une configuration désordonnée avec des liens intercellulaires faibles ou inexistants. Tous ces changements au niveau des structures cellulaires expliquent la différence de conductivité en fonction de la fréquence qui existe entre les lésions cutanées bénignes et malignes.
- Dermoscopie: c'est une technique non invasive qui permet de visualiser les lésions pigmentées de l'épiderme [MOG 07]. Le dermoscope est muni d'une source lumineuse et d'une lentille grossissante (de 10 à 100 fois). On trouve sur le marché des dermoscopes numériques et analogiques avec différentes résolutions. Le numérique se prête à une sauvegarde de toutes les informations et à leur utilisation pour les prochaines étapes[NOW 16][SMA 13]. Les propriétés optiques des couches superficielles de la peau peuvent alors être inspectées. Des études ont montré que la dermoscopie augmente la sensibilité diagnostique des lésions pigmentées malignes. Cette technique est utilisée par les médecins en raison de la facilité de son utilisation et de son coût bas.

I.3.2. Le prétraitement

L'objectif de cette étape est de réduire les bruits, améliorer la qualité et la lisibilité des images. L'amélioration de la qualité de l'image concerne la correction et l'étalonnage des couleurs, la correction de l'éclairage, l'accentuation du contraste et l'amélioration des bords pour une meilleure exploration et visibilité des détails figure I.4.



(a) (b) (c) (d) (e)

Figure I.4. Types de bruits courants : contour sombre (a), poil de peau (b), gel dermoscopique (c), marqueur de règle (d) et marqueur d'ancre (e)

Les bruits dépendent dans la plupart des cas du type de techniques d'acquisition d'images utilisée. La détection des frontières peut également être affectée par des caractéristiques intrinsèques telles que les vaisseaux sanguins, les poils et les lignes de la peau [MAH 15][SAL 18a].

La procédure d'élimination du poil comprend deux étapes : la détection et la restauration. Comme le poil est un composant intégral par rapport aux autres types de bruit, la plupart des méthodes développées pour la détection utilise la segmentation. La seconde étape consiste à restaurer l'espace occupé par les poils retirés avec des valeurs d'intensité et de couleur appropriées. La qualité de l'image obtenue peut être affectée lorsque la densité des cheveux est importante dans la bordure de la lésion. Ainsi, le rasage de la zone concernée, lorsqu'il est possible, demeure une bonne solution et un compromis pour réduire les erreurs de diagnostic.

Les méthodes de prétraitement d'image incluent le filtrage et les techniques basées sur l'histogramme, le filtre gaussien et le filtre médian ont été largement utilisés pour éliminer le bruit des images médicales, lisser les variations de coloration. Le lissage des images médicales a été assuré par d'autres techniques dont : la diffusion anisotrope basée sur l'équation différentielle partielle (EDP), le filtrage bilatéral, qui préserve les contours mais supprime le bruit.

L'égalisation et la normalisation de l'histogramme sont les deux techniques qui ont été utilisées pour éliminer les variations de couleur dues au processus de coloration et aux conditions d'illumination.

I.3.3. Segmentation

Dans le traitement et l'analyse des images médicales, les images issues des différentes modalités (scanner, IRM,…) doivent être segmentés pour identifier leurs principaux composants. Une image se compose d'un certain nombre d'objets physiques définis par des

régions distinctes. Le fond de l'image en lui-même est une région distincte. Ces régions sont définies par leurs frontières qui les séparent des autres régions. La segmentation de l'image vise à identifier ces limites et identifie les pixels qui appartiennent à la région. Pour le traitement de l'image dermoscopique, seule la région englobant la lésion constitue un centre d'intérêt pour les processus ultérieurs tels que l'extraction des caractéristiques, l'analyse de la forme du contour et de la texture. Leur segmentation reste très difficile. Une des raisons principales de cette situation est la nature des images. Ces objets n'ont pas souvent des frontières très bien définies dans images notamment dans le cas où les différences de niveaux de gris entre un objet et son fond sont mal contrastés ; ce qui rend difficile, pour un algorithme de segmentation, de générer une limite précise. Dans de tels cas, il faut s'attendre à ce que des erreurs de segmentation soient commises et que les pixels seront à tort attribués à une zone et le résultat serait une définition imprécise des régions dans les images. L'avantage de disposer d'un contour précis devrait faciliter la tâche d'un système de reconnaissance des lésions. En d'autres termes, la qualité de la segmentation influe directement sur les résultats obtenus par les traitements situés en aval de l'étape de segmentation et conditionne aussi bien la qualité de l'interprétation que la prise de décision.

La segmentation des images des lésions cutanées a été aperçue à partir d'une large variété de points de vue. Elle englobe le seuillage à partir de l'histogramme [KOR 12], les approches de segmentation basées sur la frontière [ZHO 10] , les méthodes arbres / graphe, la segmentation par région [VIC 17], le regroupement, ou approches probabilistes bayésiennes, la segmentation par les réseaux neuronaux et d'autres approches. D'autres méthodes dérivées de l'analyse des données comme la K-moyenne (K-means), le FCM(Fuzzy C-Means), l'EM (Expectation Maximization) ont été aussi utilisées [SRE 19][FIL 17a][FIL 17b][ABD 19].

- La segmentation par seuillage de l'histogramme n'est efficace que pour des images dont l'histogramme unimodal ou bimodal. Dans certains cas, les images peuvent être d'une qualité telle que tout prétraitement ne peut pas améliorer suffisamment le contraste entre les objets et donc on ne peut pas atteindre deux ou plusieurs pics de l'histogramme pour la sélection des seuils de segmentation. Les distributions sont généralement obtenues lorsque l'image se compose principalement d'un grand fond de zone avec de petites, mais importantes régions.
- Une gamme d'algorithmes de segmentation d'images s'appuie sur la région. Les algorithmes de croissance de la région prennent une ou plus de pixels, et explorent les régions autour d'eux, basés sur un certain critères d'homogénéité. Si les pixels adjacents sont semblables, ils sont fusionnés pour constituer une seule région. Le processus se poursuit jusqu'à ce que tous les pixels de l'image soient assignés à une ou plusieurs régions.
- L'approche frontière s'appuie sur la détection des transitions entre les régions de l'image, tente de déterminer des contours ou frontières de régions correspondant à une

variation brutale de l'intensité lumineuse ou à une discontinuité entre les propriétés de deux ensembles de points connexes. Les détecteurs de contours généralement utilisés sont les opérateurs de Sobel, de Roberts, de Prewitt, l'opérateur de Canny, et les contours actifs.

- La segmentation d'image peut être effectuée de manière efficace par des méthodes issues de l'analyse des données. L'analyse typologique permet la séparation des données en sous-groupes significatives. L'analyse de clustering nécessite soit que l'utilisateur fournisse les classes pour les régions à segmenter ou utiliser des méthodes non paramétriques pour trouver les régions sans avoir l'exigence des points de chaque classe. Le Clustering est couramment utilisé dans une variété d'applications telles que la segmentation d'images et l'apprentissage non supervisé. Un certain nombre de questions liées au regroupement méritent d'être étudiés, y compris combien de groupes sont les meilleurs et la façon de déterminer la validité des clusters. Dans un certain nombre de techniques de segmentation, comme fuzzy c-means clustering, le nombre de groupes présents dans l'image doit être spécifié à l'avance.

I.3.4. Extraction des caractéristiques

Une fois la région d'intérêt isolée, l'objectif de cette étape est de fournir le meilleur descripteur des caractéristiques qui discriminent la base de données en deux classes ou plus. Le mélanome est visuellement difficile à différencier des lésions non-mélanome qui sont des tumeurs bénignes. L'extraction de caractéristiques est effectuée par des mesures de certaines propriétés, ou caractéristiques, qui différencient un modèle d'entrée d'un autre. Il est important d'identifier les caractéristiques les plus performantes à extraire de l'image du mélanome, ainsi de trouver les critères et les algorithmes de classification les plus efficaces pour différencier ces lésions.

La couleur est un attribut visuel de forme qui résulte l'absorption et la réflexion de la lumière par les objets. La couleur fournit des informations supplémentaires qui permettent de distinguer les différentes causes physiques des variations de couleurs, qui est une propriété discriminante importante des objets. Les caractéristiques des couleurs sont principalement des paramètres statistiques calculés à partir de différents canaux de couleur, comme la valeur moyenne et l'écart type des canaux de couleur Rouge, Vert, Bleu (RVG ou RGV) ou Teinte, saturation, luminosité (TSL). Les autres caractéristiques de couleur utilisées dans différentes études comprennent l'asymétrie des couleurs, la distance centroïdale, la distance de l'histogramme LUV, etc [CEL, 07][MA 15]. Certains chercheurs ont utilisé des caractéristiques de texture basées sur la co-occurrence matrice (GLCM) comme, le contraste, l'énergie, la probabilité maximale, la corrélation, l'entropie, etc [MOH 13][ANS 17].

I.3.5. Sélection des caractéristiques

De nombreuses caractéristiques potentielles peuvent être utilisées, mais il est important de sélectionner un nombre réduit raisonnable de caractéristiques utiles tout en éliminant les caractéristiques redondantes, non pertinentes ou bruyantes. Cependant, il est important de s'assurer qu'il ne peut y avoir de perte d'informations importantes.

La sélection de caractéristiques peut être définie comme un processus visant à sélectionner le meilleur sous-ensemble optimal parmi l'ensemble original des caractéristiques qui a la puissance de prédiction maximale pour la sortie. La sélection de caractéristiques permet [FIL 18][ABD 19]:

- Une réduction du temps d'extraction des caractéristiques, des exigences de stockage, de la complexité du classificateur pour un meilleur comportement de généralisation,
- Augmentation de la précision des prévisions,
- Réduction des temps de formation et de test, et amélioration de la compréhension et de la visualisation des données[VIS 15].

I.3.6. Classification

L'étape finale est la classification et le diagnostic, où le système DAO proposé est observé et analysé. La performance d'un tel système repose en grande partie sur la qualité du classificateur utilisé et les problématiques entourant la préparation des données. En fonction des caractéristiques extraites et du nombre de classes souhaitées, le choix du classifieur est primordial pour obtenir de meilleurs résultats relatifs à la détection. Généralement, les lésions de cancer de la peau sont classier suivant deux ou trois classes qui sont bénignes/malignes et nævus/atypiques/ mélanome.

Dans la littérature, de nombreuses approches de classification du cancer de la peau ont été proposées [CEL 07][OZK 17][NAS 18]: Arbres de décision (Decision Tree, AD), Régression logistique, k plus proches voisins (K-Nearest Neighbors , KNN) et les machines à vecteurs de support (Support Vector Machine, SVM). Les arbres de décision, SVM et KNN sont utilisés sous différentes formes :

- Noyaux linéaires, quadratiques et gaussiens pour le SVM.
- Fines, moyennes, cubiques distances pondérées pour le KNN
- Modèles simples, moyens et complexes pour les arbres de décision.

I.3.7. Travaux antérieurs

Le tableau 1 formule les techniques adoptées pour chaque étape du traitement des images dermoscopiques en vue d'une classification. Il en ressort que dans l'étape inévitable de prétraitement, les techniques utilisées afin d'améliorer la qualité des images à travers la

réduction des divers les bruits liés au conditions de l'acquisition, aux performances du capteur, la plupart utilise le filtre médian et l'égalisation de l'histogramme. Quant à la segmentation, la technique de prédilection reste le seuillage OTSU. A l'étape d'extraction d'attributs, on peut remarquer que de nombreux chercheurs ne prennent en considération qu'un seul paramètre à savoir la texture, la couleur ou la forme, tandis que d'autres prennent en compte les trois paramètres mais n'utilisent que quelques caractéristiques (attributs) pour chacun d'eux. Ces deux façons d'opérer ne permettent pas d'obtenir une classification fiable car certaines lésions peuvent ne pas être discriminées.

Tableau I.1. Travaux antérieurs

	Prétraitement	*Segmentation*	*Extraction des caractéristique*	*Type de classification*
[FAS 11]	*Filtre médian*	*Opérateurs morphologiques*	*Ondelettes*	*RNA*
[JAL 12]	*Filtre médian*	*Seuillage*	*Ondelettes*	*RNA*
[MAD 12]	*Filtre médian*	*Seuillage* *Détection de frontières*	*Algorithme de Stolz*	*RNA*
[JAL 13]	*Filtre médian*	*Seuillage.*	*Matrice de cooccurrence et attributs de couleurs*	*RNA*
[OOM 13]	*Filtre médian*	*Seuillage.*	*Règle ABCD* *TDS,*	*SVM* *RNA*
[MOH 13]	*Filtre médian*	*K-means*	*Sélection du mode séquentiel*	*SVM*
[MHA13]	*Filtre médian* *égalisation d'histogramme*	*Seuillage*	*Ondelettes*	*SVM* *RNA*
[ABU 14]	*Médian adaptatif* *filtre de Gabor* *égalisation d'histogramme*	*Seuillage*	*sélection de mode séquentiel*	*SVM*
[TAK 14]		*K-means*	*Ondelettes* *Curvelettes* *Couleur*	*SVM*
[SAB 14]	*Filtre morphologique* *filtre médian adaptatif*	*Otsu*	*Entropie* *Matrice de cooccurrence*	*K-NN,* *Naïve Bayes,* *perceptron multicouche,*

				forêt aléatoire et MSV
[ELG 13]			*Ondelettes ACP*	*RNA K-NN*
[NAS 18]			*Couleur, la texture et la forme (HOG) Entropie*	*SVM*
[AKR 18]	*Stretching contraste*		*Couleur, Diamètre, bordure*	*SVM*
[KHA 19a]	*Filtre gaussien*	*K-means*	*Texture et couleur*	*SVM*
[DAL 17]	*Composante verte*	*Colonie de fourmis*	*Texture et couleur*	*RNA KNN,*
[WAH 17]			*Couleur pour le RVB et HSV ; texture*	*SVM*
[PAT 19]	*Lissage de l'image*	*Active contour*	*Ensemble de caractéristique*	*Adaboost*
[MOU 18]	*TSL décomposition*		*Texture, couleur et transfert Learning*	*KNN, SVM*
[GON 17]	*Augmentation de la base de donnée*			*Convolution neuronal network (CNN)*

I.4. Évaluation d'un système d'aide au diagnostic médical

Un système de DAO est généralement basé sur trois étapes: la segmentation de l'image, l'extraction / sélection des caractéristiques et la classification des lésions. Chacune de ces comporte des défis et nécessite une évaluation et une validation appropriées et de disposer de données de référence fiables (ou de vérité terrain). Les données de référence doivent être préparées et validées par des dermatologues experts.. l'évaluation en phase opérationnelle ou de test s'effectue généralement dans un contexte de détection ou de reconnaissance. L'étape de classification supervisée comprend deux étapes, à savoir l'entrainement et le test. Lors de l'étape de l'entrainement, un classificateur est entrainé sur un ensemble de vecteurs de caractéristiques d'entrainement avec une étiquette assignée. Lors de l'étape de test, le classificateur est appliqué à un ensemble de vecteurs de caractéristiques de test qui ont été

conservés à des fins de test (et qui sont différents des vecteurs de caractéristiques d'entrainement), ainsi les performances du classificateur sont évaluées[DRE 01][LOP 17]

I.4.1. Les critères d'évaluation

Les critères usuels permettant d'évaluer la qualité des estimations sont la sensibilité ou rappel, la spécificité, précision, exactitude, F-mesure et le Coefficient Kappa.

La sensibilité et la spécificité permettent d'affiner l'évaluation en quantifiant le taux de vrais positifs et le taux de vrais négatifs.

Sensibilité ou rappel : mesure la capacité à donner un résultat positif lorsqu'une hypothèse est vérifiée.

$$Sénsibilité\ ou\ rappel = \frac{VP}{VP\ +\ FN} \qquad (I.1)$$

Spécificité : mesure la capacité à donner un résultat négatif lorsque l'hypothèse n'est pas vérifiée.

$$Spécificité = \frac{VN}{FP\ +\ VN} \qquad (I.2)$$

- VP (Vrai Positif): Sujet malade et positif par le DAO,
- FP (Faux Positif) : Sujet non malade et positif par le DAO,
- VN (Vrai Negatif) : Sujet non malade et négatif par le DAO et
- FN (Faux Negatif) : Sujet malade et négatif par le DAO.

Précision : mesure la proximité des mesures les unes par rapport aux autres

$$Précision = \frac{VP}{VP\ +\ FP} \qquad (I.3)$$

Exactitude (Accuracy) : mesure l'exactitude du système.

$$Exactitude = \frac{VP + VN}{VP + VN + FP + FN} \qquad (I.4)$$

Le positif et le négatif font référence à la décision prise par l'algorithme et les termes vrai et faux à la manière dont la décision est en accord avec l'état clinique réel.

F-mesure : calcule la valeur harmonique qui combine la précision et le rappel

$$F - mesure = \frac{2 * (précision * rappel)}{précision + rappel} \qquad (I.5)$$

Coefficient Kappa : mesure l'accord entre observateurs lors d'un codage qualitatif en catégories.

$$Kappa = \frac{total\ accuracy - random\ accuracy}{1 - random\ accuracy} \qquad (I.6)$$

Avec:

$$Random\ Accuracy\ = \frac{(TN + FP) * (TN + FN) + (FN + TP) * (FP + TP)}{Total * Total} \qquad (I.7)$$

I.4.2. Bases de données

Actuellement, il y a plusieurs bases de données publiques et gratuites, construites pour effectuer et comparer l'évaluation de plusieurs systèmes, qui fournissaient des masques de segmentation binaire correspondants (figure I.5). Dans nos expériences de segmentation et de classification, la validation des approches proposées portent sur trois base de données distinctes : PH2 [MEN 13],ISIC2017 [COD 17], et atlas démoscopies [http://www.dermoscopyatlas.com].



Figure I.5. Image de la base de données PH2 avec masque de segmentation

1. La base de donnée Ph2

La base de données se compose de 200 images dermoscopiques avec les annotations médicales correspondantes, comprenant 80 naevus communs, 80 naevus atypiques et 40 mélanomes malins. Les images dermoscopiques ont été acquises avec un grossissement de 20 fois dans des conditions inchangées. Ce sont des images couleur RBG codées sur 8 bits avec une résolution de 768 × 560 pixels. Pour chaque image de la base de données, la segmentation manuelle et le diagnostic clinique de la lésion cutanée ainsi que l'identification d'autres critères dermoscopiques importants sont disponibles. Quelques images illustratives de la base de données PH2 est présentée sur la figure I.6.

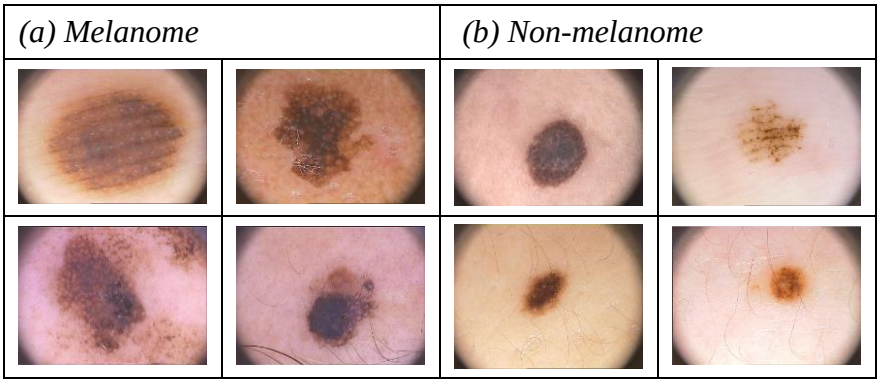

Figure I.6. Un échantillon d'images de la base de données PH2

2. ISIC 2017

L'ISIC (International Skin Imaging Collaboration) est un partenariat entre le monde universitaire et l'industrie qui vise à soutenir les efforts visant à réduire les décès liés au cancer de la peau et les biopsies inutiles. L'ensemble de données ISIC2017 contient 2000 images : 1626 cas de cancer de la peau sans mélanome (254 kératoses séborrhéiques, 1372 naevus atypiques) et 374 mélanomes. Ces images sont de couleurs RVB (rouge, vert, bleu) et ont une résolution de 767*1022 pixels. La figure I.7 présente des exemples de la base de données.

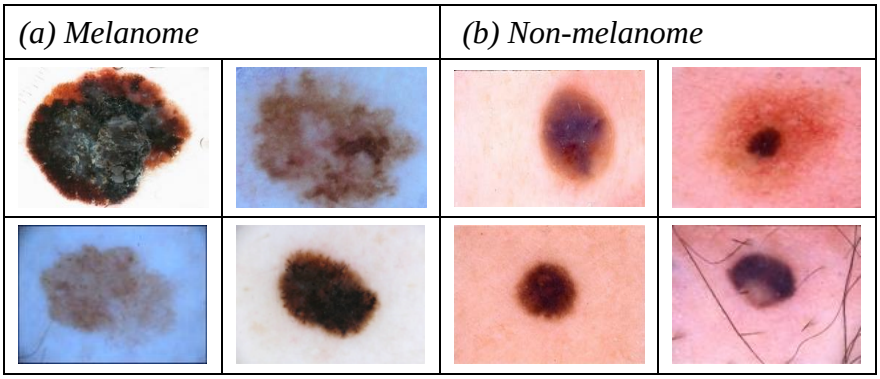

Figure I.7. Un échantillon d'images de la base de données ISIC2017

3. Atlas dermoscopy

Il contient 80 images de lésions cutanées pigmentées : 20 cas de cancer de la peau mélanome (kératoses séborrhéiques, naevus atypiques) et 60 non-mélanomes. Ces images sont en de couleurs RVB (rouge, vert, bleu) et ont une résolution de 451*550 pixels. La figure I.8 présente des exemples de la base de données.

Les trois bases de données sont classées par des experts et contiennent la vérité de base de la segmentation.

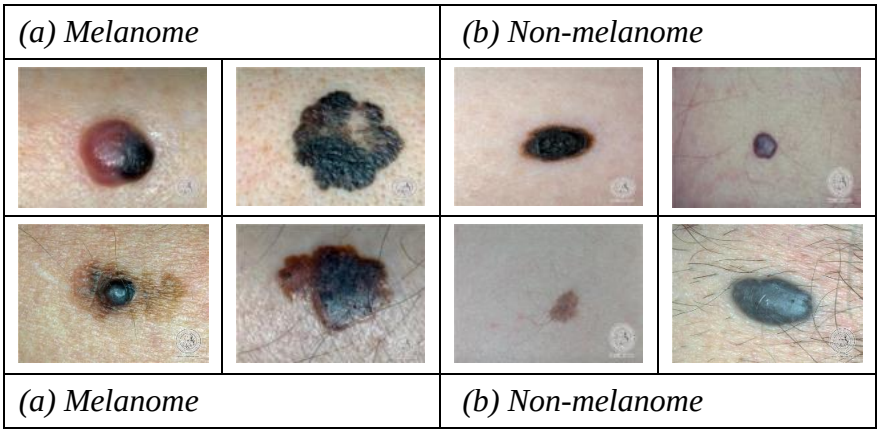

Figure I.8. Un échantillon d'images de la base de données Atlas dermoscopy

I.5. Conclusion

Les images médicales sont actuellement disponibles en quantité abondante, de nouvelles méthodes sont requises pour mieux extraire d'une manière efficace les informations de ces images à travers un apprentissage automatique. L'analyse d'images fondée sur l'apprentissage automatique et profond ont conduit récemment à des avancées significatives dans le dépistage précoce de pathologies, dans l'aide au diagnostic, ou dans la segmentation de structures anatomiques. Avant de procéder à une description des fonctions des systèmes d'aide à la décision (DAO), dans ce chapitre nous avons présenté une brève description de la cancérogenèse et de la procédure de l'examen clinique. Par la suite, la méthodologie de conception de ces systèmes ainsi que les étapes nécessaires à leurs réalisations sont présentées.

Chaque processus des Systèmes DAO (SDAO) influence la performance du diagnostic des lésions cutanées et parmi les phases principales des SDAO, nous trouvons : le prétraitement, la segmentation, l'extraction des caractéristiques, et les algorithmes de classification. Dans le prochain chapitre nous commençons par la visualisation de l'impact de la segmentation des images de dermatologie sur la diagnostique artificiel.

Chapitre II:
Contributions à la segmentation et la caractérisation des images Dermoscopique.

II.1. Introduction

La segmentation a un impact direct sur le résultat de la classification et attire plus d'attention de nombreux chercheurs. En effet, une segmentation directe entraînera une fausse détection et identification de la région de la lésion et forcément le taux de classification serait faible même avec le meilleur algorithme de classification. Alors qu'une bonne segmentation contribuerait à un taux de classification élevé même avec un classificateur très basique. Plusieurs algorithmes de segmentation ont été proposés dans la littérature pour identifier et détecter la lésion cutanée, telle que la segmentation par région [VIC 17], la segmentation par seuillage [KOR 12] et la méthode des contours actifs [Zho 2010]. D'autres méthodes dérivées de l'analyse des données comme la K-moyenne (K-means), le Fuzzy C-Means (FCM), l'Expectation et Maximisation (EM), les réseaux neuronaux artificiels (RNA) ont été aussi utilisées [SRE 19]. Ces méthodes ont été combinées avec des métaheuristiques comme les Algorithmes Génétiques (GAs) [ABD 19].

Dans ce chapitre, nous présentons d'abord une nouvelle approche de segmentation de l'image de la lésion qui tire profit d'une décomposition multi échelle utilisant les Equations aux Dérivées Partielles (EDP). Le résultat de cette décomposition aboutit à deux composantes; une composante qui contient le bruit et la texture présents dans l'image et une composante qui ne contient que les objets ayant plus ou moins une structure homogène. Au lieu de segmenter l'image initiale, la segmentation est effectuée sur la composante objet obtenue à partir de cette décomposition. L'efficacité de cette approche est évaluée pour une série d'algorithmes usuels de segmentation. Ensuite, nous présentons la proposition de nouveaux attributs discriminants de la forme qui caractérise le squelette de la lésion en tant que signature. La dernière partie est consacrée à l'étude de sélection des caractéristiques. Nous présentons d'abord les caractéristiques, de couleur et de texture, retenues pour la classification puis une description des méthodes d'évaluation et de sélection adoptées et en fin les résultats de simulation obtenus.

II.2. Approches de segmentation

Les images des lésions cutanées contiennent des artefacts généralement comme des poils, des ombres et des lignes de peau [MAH 15][JAN 18]. Une segmentation directe de ces images aboutit inéluctablement à une détection et identification incorrecte de la lésion. Il est alors nécessaire de procéder à un prétraitement afin de préparer et améliorer l'image pour une segmentation avec succès. Les filtres linéaires, non linéaires et morphologiques sont largement utilisés dans cette étape. Les filtres linéaires ne sont efficaces que pour un traitement spécifique, alors que les filtres non-linéaires peuvent être utilisés pour éliminer les artefacts comme les ombres et les poils tout en préservant les bords de la lésion et quant aux filtres morphologiques sont efficaces pour les lésions ayant un très faible contraste [JAN 18].

La segmentation des images dermoscopiques des lésions cutanées constitue une étape cruciale dans le processus de classification des images des lésions cutanées utilisant l'apprentissage automatique. Une bonne segmentation implique une meilleure identification et détection de la lésion. Plusieurs algorithmes de segmentation sont proposés dans la littérature pour la segmentation des lésions cutanées. Nous proposons une nouvelle une approche de segmentation de l'image de la lésion qui s'appuie sur une décomposition multi échelle en deux composantes : une composante « objet » et une composante « texture » cette décomposition est établie au moyen d'une modélisation par les Equations aux Dérivées Partielles (EDP). La segmentation est effectuée sur la composante « objet » au lieu de l'image initiale de la lésion. Nous commençons par une description sommaire du fondement théorique du modèle variationnel adopté suivie de l'évaluation des performances des algorithmes usuels de segmentation appliqués à la composante dite objet.

II.2.1. Modèle de décomposition variationnel

Dans le domaine du traitement d'image, les approches basées sur les EDPs ont eu un très grand intérêt et leur efficacité a été prouvée dans le domaine de réduction de bruit, d'indexation/recherche, de tatouage, de filtrage, de restauration, recalage, fusion et segmentation.

La décomposition variationnelle repose sur des formulations mathématiques qui dépassent le cadre de cette thèse, nous nous sommes limités aux algorithmes qui traduisent les solutions numériques de ces modèles**.** Parmi les modèles variationnels appliqués dans la restauration d'images et le filtrage du bruit, Rudin, Osher et Fatimi (ROF) ont présenté un modèle de minimisation basé sur la variation totale. Ce modèle traite de la restauration d'images qui consiste à reconstruire l'image original non bruitée **u** à partir d'une image dégradée **f**, a été modélisé par une transformation linéaires plus un bruit additif **n** :

$$\boldsymbol{u = Af + n} \qquad \textit{(II.1)}$$

où **A** est un opérateur linéaire.
La solution est généralement sous la forme suivante :

$$\inf_{u} \underbrace{\|Au - f\|_2^2}_{\textit{attache aux données}} + \underbrace{L(u)}_{\textit{régularisation}} \qquad \textit{(II.2)}$$

Avec $\mathbf{L(u)} = \|\nabla \mathbf{u}\|_2^2$,

Ce type de régularisation ne s'avère pas un bon choix en traitement d'image, en particulier, les bords de l'image sont érodés et il n'est pas bien adéquat pour la restauration des images. Pour pallier cet inconvénient**,** dans le modèle ROF, le terme de régularisation porte sur la variation totale de l'image. Ce modèle est défini alors par (dans le cas ou l'opérateur A égal à l'identité) :

$$\inf_{u \in VB(\Omega)} \quad \frac{\lambda}{2}\|f-u\|_{L^2} + J(u) \qquad (II.3)$$

où λ est un paramètre de régularisation : si λ est choisi trop petit, la reconstruction sera dominée par des composantes à hautes fréquences. En revanche, si $\boldsymbol{\lambda}$ est choisi trop grand, les informations importantes dans les données ne seront pas prises en compte.

Le modèle de ROF permet de restaurer une image initiale u à partir d'une image dégradée de l'image originale f et son interprétation peut donner un modèle de décomposition où **f** présente l'image initiale constituée de deux composantes [GIL 06] :

$$f = u + v \qquad (II.4)$$

La première composante, **u**, contient l'information géométrique de l'image. On peut la considérer comme une esquisse de l'image originale **f**. Elle contient les contours de l'image ainsi que les niveaux de gris moyens. La deuxième composante, **v**, représente la somme des textures et du bruit présent dans l'image originale **f**.

Les simulations numériques de ce modèle ont montré que la composante **u** contient parfois les objets de l'image originale, et la composante **v** contient les textures mais aussi des objets. Pour remédier à cet inconvénient**,** Y. Meyer a proposé une amélioration en introduisant un espace a priori mieux adapté aux phénomènes oscillants. Ce nouveau modèle a prouvé son efficacité à assurer les discontinuités dans l'image tout en éliminant les oscillations. D'autres modèles inspirés du modèle ROF ont été par la suite élaborés et appliqués dans plusieurs domaines du traitement d'images.

L'algorithme d'Aujol permet de calculer la solution numérique du modèle de Meyer et ainsi à séparer une image en deux composantes, la première contient l'information géométrique et la seconde l'information oscillante (texture et bruit). Deux versions ont été élaborées qui se diffèrent dans l'étape itérative. Dans la première, on minimise d'abord par rapport à $\boldsymbol{v}$ puis par rapport à $\boldsymbol{u}$ et dans la seconde, on minimise d'abord par rapport à $\boldsymbol{u}$ puis par rapport à $\boldsymbol{v}$**.**

Algorithme :
Etape 1 : Initialisation

$$u_0 = v_0 = 0$$

Etape 2 : Itérations

$$v_{n+1} = P_{G_\mu}(f - u_n)$$
$$u_{n+1} = f - v_{n+1} - P_{G_\lambda}(f - v_{n+1})$$

Etape 3 : Condition d'arrêt
On arrête l'algorithme si

$$max(|u_{n+1} - u_n|, |v_{n+1} - v_n|) \leq \varepsilon$$

ou si l'on atteint un nombre maximal d'itérations prescrit.

La figure II-1 illustre un exemple de la décomposition par l'algorithme de Aujol pour des images dermoscopiques.

On peut observer qu'effectivement la composante objet contient uniquement la lésion alors que la texture est présente seulement sur la composante texture.

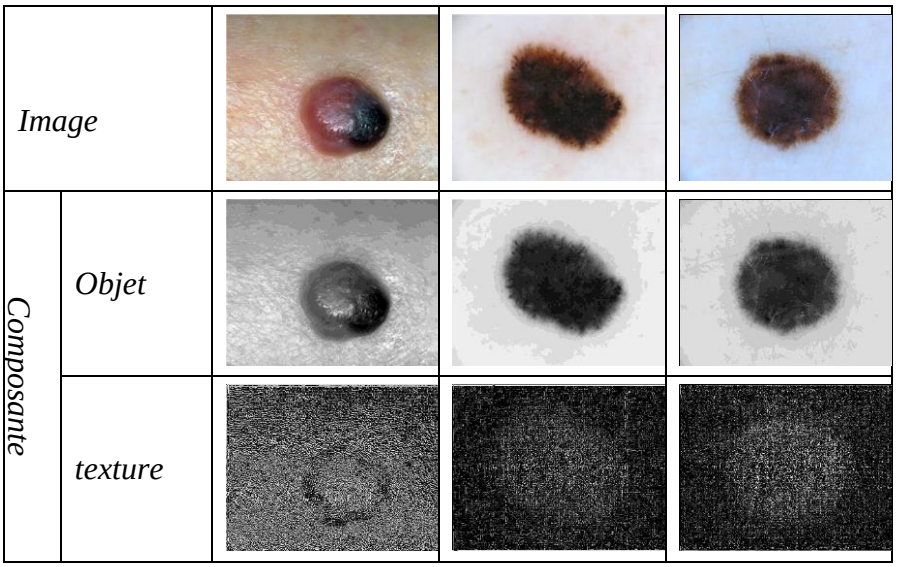

Figure II.1. Résultats de la décomposition

II.2.2. Étude des performances

Dans cette section nous présentons une étude comparative d'un ensemble de méthodes dont chacune représente un type de segmentation comme OTSU, Contour actif, Split and merge, K-means, Fuzzy C-means et Expectation Maximization voir Table II.1.

Une comparaison est effectuée pour ces algorithmes en utilisation la décomposition et sans décomposition pour savoir le mieux adapté à la segmentation des lésions cutanées.

Tableau. II.1. Algorithmes de segmentation.

Algorithme	*Type*
1- OTSU	*Seuillage*
2- Contour actif	*Frontière*
3- Split and merge	*Région*
4- K-Means	*Clustering*
5- FCM (Fuzzy C-Means)	*Clustering*
6- EM (Expectation Maximization)	*Clustering*

II.2.2.1. Algorithmes de segmentation

1. Otsu

La méthode d'Otsu fait partie des méthodes de segmentation par seuillage à partir de la forme de l'histogramme d'une image. L'algorithme suppose l'histogramme est bimodal ; l'image ne contient que deux classes de pixels : le premier plan et l'arrière-plan. Le seuil optimal qui sépare ces deux classes est obtenu par minimisation de la variance intra-classe [GAR 11][GUP 17]. Résultat de la segmentation est présenté dans la figure II.2.

Nous avons segmenté en un premier temps l'image originale, après seule la composante objet est segmenté.

Images originales			
Segmentation directe			
Segmentation de la composante objet			

Figure II.2. Résultats de la segmentation par application de l'algorithme OTSU

2. Contour Actif

L'approche des contours actifs ou snakes de détection de contours a été proposée par Kass, Witkins et Terzopoulos [KAS 88]. Elle part d'une ligne initiale de contour qui se déforme sous l'action de plusieurs forces :

- Une énergie propre, assimilée à l'énergie mécanique de tension et de torsion d'une ligne matérielle,
- Une énergie potentielle imposée par l'image qui vise à plaquer la courbe sur les contours,
- Une énergie externe, introduite par l'utilisateur pour traduire les contraintes spécifiques du problème qu'il se pose.

Sous ces énergies, le contour actif est amené à évoluer dans le sens de minimiser la configuration relative à l'énergie minimale, qui représente un compromis entre les diverses contraintes du problème. Le problème majeur rencontré dans le modèle traditionnel est que

le contour initial doit être en général, proche de la frontière réelle, sinon il mène un résultat incorrect. Le résultat de segmentation en utilisant l'algorithme d'active contour est présenté dans la figure II.3 ;

Images originales			
Segmentation directe			
Segmentation de la composante objet			

Figure II.3. Résultats de la segmentation par application de l'algorithme contour actif

3. Split and merge

Le processus de segmentation est itératif et alterne deux phases. Il consiste, dans une première phase, à découper l'image en zones de taille moyenne (le plus souvent en quatre quadrants), puis à parcourir chacune des régions en cherchant si elle vérifie un critère d'homogénéité. Les régions non homogènes sont à leur tour divisées en sous-blocs. Ce processus de découpage de régions non homogène est poursuivi jusqu'à obtenir que des régions homogènes. Une deuxième phase de fusion permet par la suite de regrouper les zones contigües correspondant à la même région.

Images originales			
Segmentation directe			
Segmentation de la composante objet			

Figure II.4. Résultats de la segmentation par application de l'algorithme Split and merge

Cette approche utilise des propriétés globales pour diviser l'image en zones homogènes puis à fusionner certaines de ces régions grâce à des caractéristiques locales. Le critère du test de l'homogénéité de la région porte sur les niveaux de (intervalle, moyenne, variance).

Le résultat de segmentation en utilisant l'algorithme Split and merge est présenté dans la figure II.4 ;

4. K-means

K-Means est un algorithme de regroupement non supervisé qui classifie les points de données d'entrée en plusieurs classes en fonction de leur distance inhérente les uns par rapport aux autres. L'algorithme itératif K-Means a été proposé pour la première fois par MacQueen [MAC 67]. K-Means est largement utilisé dans de nombreuses applications telles que l'extraction de données et la segmentation d'images.

L'algorithme commence avec un ensemble de K centroïdes initial aléatoire qui constituent des points de départ centraux pour chaque groupe. Chaque pixel de l'image est ensuite assigné au centre de la classe la plus proche en fonction d'une mesure de distance. L'objectif à atteindre est de minimiser la variance totale intra-groupe (somme des distances au carré entre tous les points et le centre du groupe).Les centres sont mis à jour en utilisant la moyenne des pixels associés. Le processus est répété jusqu'à ce que le critère d'arrêt soit vérifié.

Le résultat de segmentation en utilisant l'algorithme K-means est présenté dans la figure II.5 ;

Images originales			
Segmentation directe			
Segmentation de la composante objet			

Figure II.5. Résultats de la segmentation par application de l'algorithme K-means

5. FCM (Fuzzy C-Means)

Il s'agit d'une méthode non supervisée d'analyse des données, il a été mentionné pour la première fois par Joe Dunn qui implique de minimiser une fonction objective [DUN 73], appartient au groupe objectif des algorithmes de fonction. Lorsque l'algorithme est capable de minimiser une fonction d'erreur, on l'appelle souvent C-Means étant c la nombre de classes ou de groupes, et si les classes utilisées utilisent la technique floue ou simplement floue, alors on sait qu'elle est FCM. Les objets situés à la limite entre plusieurs classes sont ne sont pas forcés d'appartenir pleinement à l'une des classes, mais sont plutôt a attribué des degrés d'appartenance entre 0 et 1 indiquant leur l'adhésion partielle.

Images originales			
Segmentation directe			
Segmentation de la composante objet			

Figure II.6. Résultats de la segmentation par application de l'algorithme Fuzzy C-means

La méthode de la FCM utilise un degré d'adhésion pour chaque classe, et utilise un partitionnement flou tel qu'une donnée peut appartenir à tous les groupesayant une composition différente des notes entre 0 et 1.

Le résultat de segmentation en utilisant l'algorithme FCM est présenté dans la figure II.6 ;

6. EM (Expectation Maximization)

La maximisation des espérances (EM) est l'une des algorithmes communs utilisés pour l'estimation de la densité des points de données dans un regroupement non supervisé [DEM 77]. L'objectif est d'estimer les moyennes et les écarts-types pour chaque groupe afin de maximiser la probabilité des données observées (distribution). L'algorithme EM tente d'approximer les distributions de valeurs observées en se basant sur des mélanges de différentes distributions dans différents groupes. Dans l'algorithme EM, des étapes alternées d'attente (E) et de maximisation (M) sont effectuées de manière itérative jusqu'à ce que les

résultats convergent. L'étape d'attente est l'affectation et l'étape de maximisation est la mise à jour des centres.

Le résultat de segmentation en utilisant l'algorithme EM est présenté dans la figure II.7 ;

Images originales			
Segmentation directe			
Segmentation de la composante objet			

Figure II.7. Résultats de la segmentation par application de l'algorithme Expectation Maximisation

II.2.2.2. Résultats des simulations

Les figures précédentes (Figure II,(2,3,4,5,6,7)) présentent les résultats de la segmentation par application des six algorithmes. Il est clair que la lésion n'est pas correctement segmentée, ce qui affectera les caractéristiques extraites et donc la précision de la classification. Cela est dû à la présence de texture, d'artefacts, de reflets et de lignes de peau qui gênent le résultat de la segmentation. Par contre, on peut constater que le prétraitement a nettement amélioré les résultats des segmentations, puisque la segmentation est appliquée à la composante objet.

La segmentation des lésions cutanées, effectuée pour chacun des algorithmes décrits précédemment est évaluée sur la base d'image du challenge ISIC[COD 17]. Cette base est proposée avec le terrain vérité permettant de calculer la sensibilité et la spécificité utilisées en tant que mesures d'évaluation. Le tableau II.2 suivant regroupe les résultats obtenus pour les deux types de segmentation avec et sans décomposition préliminaire.

Tableau. II.2. Sensitivité et spécificité pour toute la base de donnée sans et avec prétraitement

Segmentation sans décomposition						
	Otsu	*Split and merge*	*Active contour*	*FCM*	*k-means*	*EM*
Sensitivité	*82.56*	*80,15*	*87.20*	*86,15*	*88,57*	*87,96*
Spécificité	*84.83*	*82,30*	*88.23*	*86,30*	*89,33*	*86,95*
Segmentation avec décomposition						
	Otsu	*Split and merge*	*Active contour*	*FCM*	*K-means*	*EM*
Sensitivité	*96.60*	*92.302*	*96.351*	*95,17*	*98,17*	*97,00*
Spécificité	*95.20*	*93.20*	*94.95*	*94,30*	*97,32*	*96,96*

Les valeurs de sensibilité et de spécificité montrent l'utilité de la segmentation effectuée à la suite de la décomposition et apporte une nette amélioration des valeurs de sensitivité et de spécificité pour les tous algorithmes étudiés. Il en résulte qu'avec la décomposition proposée, on peut obtenir à une segmentation très satisfaisant sans avoir recours à un algorithme complexe. En conclusion, le prétraitement avec la décomposition variationnelle permet d'éliminer tout type de bruit et de texture contenu dans l'image correspondant à la composante objet.

II.3. L'ingénierie de caractéristiques

Concevoir un modèle de classification performant repose sur plusieurs facteurs :

- Choix des caractéristiques pertinentes
- Type et cohérence de la base de données (base de données équilibrées)
- Choix d'un algorithme de classification puissant

Les caractéristiques à utiliser comme entrée de la classification sont déterminantes et ont un impact direct plus que tout autre paramètre sur la qualité de la classification. Aucun algorithme de classification même puissant ne peut remplacer à lui seul le les informations que les caractéristiques procurent. Selon une enquête de Forbes, les datascientists consacrent 80 % dans l'ingénierie de caractéristiques (Extraction; Nettoyage et organisation) de leur temps à la préparation des données. L'étape la plus importante est la réduction de la dimensionnalité.

II.3.1. Choix des caractéristiques

La figure II .8 illustre les étapes de caractérisation des lésions. Une fois l'image initiale est décomposée en deux images (« objet » et « texture ») par application de l'algorithme d'Aujol, nous procédons à la segmentation de l'image objet qui permet de déterminer le contour de la lésion. L'image « texture » de la lésion est ensuite extraite par substitution des pixels du masque par ceux de l'image texture issue de la décomposition. De même l'image couleur de la lésion est obtenu en remplaçant cette fois les pixels du masque par ceux de l'image initiale. Ainsi, Les caractéristiques de couleur, de texture et de forme sont extraites respectivement des images couleur, texture et du masque de la lésion.

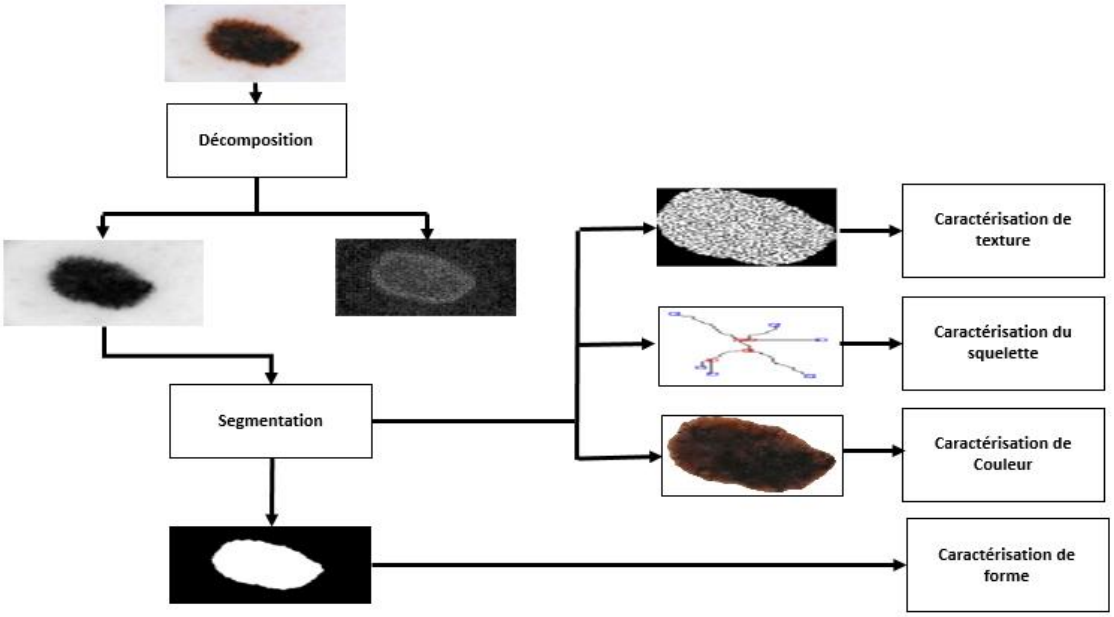

Figure II.8. Diagramme des étapes de caractérisation des images dermoscopiques

II.3.1.1. Caractéristiques de forme

La forme de la lésion est le plus important paramètre que les dermatologues utilisent dans leur diagnostic. Une lésion présentant des irrégularités sur ces bords et souvent classifiée comme étant mélanome. Il est alors indispensable de disposer de caractéristiques saillantes pour une meilleure description du masque de la lésion. Dans ce contexte, nous présentons dans cette section de nouvelles caractéristiques de forme basées sur la squelettisation qui comportent des informations pertinentes et complémentaires aux informations usuelles extraites pour décrire la forme de la lésion [FIL 20a] à savoir: La surface, Le diamètre le plus grand, Le diamètre le plus petit, Périmètre, Excentricité, Etendue, Circularité.

La squelettisation d'une image vise à fournir une représentation filaire des objets tout en préservant les informations essentielles portées par chaque objet sous sa forme la plus simple. Au départ, son application concernait la reconnaissance de caractères [ARC 85] puis elle a été

étendue à d'autres domaines de recherche : biométrie, extraction de routes, imagerie médicale pour la détection de vaisseaux sanguins, ou extraction d'architecture osseuse [ZHU 14][BEU 17].

Il existe une grande variété de méthodes de squelettisation ; les plus courantes sont basées sur l'amincissement, sur des cartes de distance, ou sur des techniques hybrides, mais chacune d'entre elles donne un résultat différent [OLI 09][SAH 16]:

- L'amincissement : Le squelette est obtenu en épluchant itérativement les couches limites de l'objet en supprimant des points individuels par des opérations morphologiques (points qui peuvent être supprimés sans changer la topologie de la forme) jusqu'à obtenir un squelette homotope de l'objet et pas nécessairement centré.
- Cartes des distances : Le principe consiste à calculer la carte de distance à l'intérieur de l'objet, pour trouver les maximums locaux et les reconnecter ensuite pour avoir le squelette souhaité. Le squelette résultant n'est pas nécessairement homotopique, fin et centré.
- Techniques hybrides : Les méthodes hybrides ont également été introduites récemment pour tirer profit des deux approches mentionnées précédemment

Dans notre travail [FIL 19b], la squelettisation est effectuée selon la technique de l'amincissement appliquée sur la lésion segmentée. La figure II .9 présente des exemples de squelettisation des lésions mélanome et non-mélanome. On peut remarquer que la forme des squelettes des lésions mélanomes présente plus de points terminaux et de bifurcations (figure II.9). Ces caractéristiques représentent judicieusement à la fois la forme de la lésion et son contour et fournissent ainsi des informations utiles pour la différentiation entre les lésions contribuant, en conséquence, à une classification efficace des lésions cutanées.

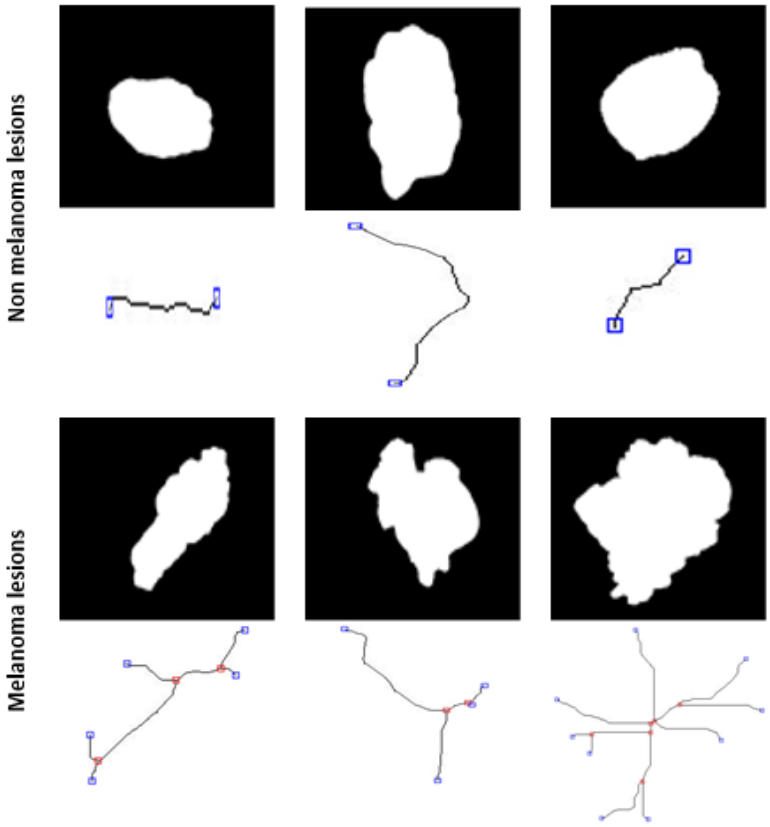

Figure II.9. Masque et squelette des lésions mélanome et non mélanome

Les caractéristiques que nous proposons d'utiliser sont basées sur la topologie du squelette et en particulier les points terminaux et les branches. Ainsi, à partir des extrémités et des branches, les paramètres pris en considération sont :

- Nombre de points terminaux : Un pixel actif qui a exactement un pixel voisin actif
- Nombre de branche : Points où deux ou plusieurs branches se rencontrent
- Nombre de sous-branches : La partie terminale d'une branche dérivée
- Taille du squelette : Nombre de tous les pixels du squelette
- Longueur du squelette
- Largeur du squelette
- Rapport entre la largeur et la longueur du squelette
- Longueur maximale entre deux points d'extrémité
- Longueur minimale entre deux points d'extrémité

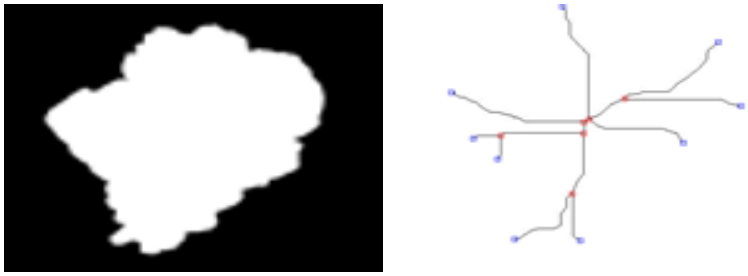

(a) (b)

Figure II.10. Caractérisation du squelette de la lésion : (a) masque de la lésion (b) Squelette ; terminaison (rond bleu) et bifurcation (rond rouge)

Pour le cas, de la lésion illustrée de la figure II.10, les valeurs des différentes caractéristiques sont : Nombre de points terminaux : 9 ; Nombre de branche : 12 Nombre de sous-branches :6 Taille du squelette :1182 ; Longueur du squelette :330 ; Largeur du squelette 356; Rapport entre la largeur et la longueur du squelette : R1 : 1.0788 ; Longueur maximale entre deux points d'extrémité : 275 ;Longueur minimale entre deux points d'extrémité: 22.

De même, une lésion asymétrique est considérée comme une lésion mélanome (figure II.11). Le critère d'asymétrie est évalué en déterminant les axes de symétrie par régression linéaire. La lésion est considérée comme asymétrique si les deux parties ne sont pas identiques et présentent des différences. Cette différence est représentée par le nombre de pixels en excès dans les deux parties asymétriques de la lésion [FIL 19a].

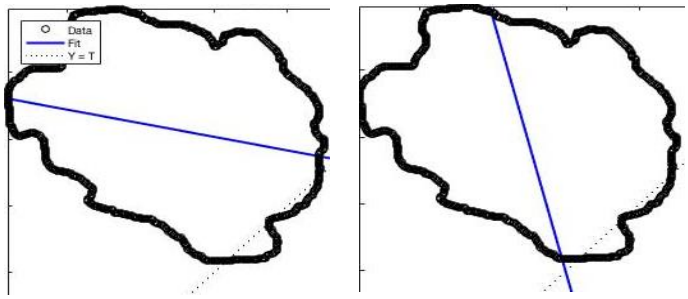

a b

Figure II.11. Droites de symétrie en bleu
(a) y=-0.1634x+392.7798 coefficient de correlation =-0.1267
(b) y=-0.0983x+240.8707 coefficient de correlation=-0.1267

II.3.1.2. Caractéristiques de couleur

L'information de couleur figure parmi les composantes de la règle ABCD que les dermatologues utilisent pour diagnostiquer et différencier visuellement entre une lésion mélanome ou non-mélanome. Une lésion susceptible d'être un mélanome est de couleur inhomogène, toutes les nuances chromatiques de la mélanine, du brun clair au noir foncé,

pouvant être observées. L'apparition des six couleurs (blanc, rouge, brun clair, brun foncé, bleu-gris et noir) est recherchée. Nous déterminons la proportion des pixels à l'intérieur du contour de la lésion correspondante à chacune de ces six couleurs. Pour ce faire, nous formulons comme suit un intervalle de définition pour chaque couleur ; comme indiqué par les équations suivante :

Blanc	$I_R(x,y) > 0{,}8$ et $I_G(x,y) > 0{,}8$ et $I_B(x,y) > 0{,}8$	*(II.5)*
Rouge	$I_R(x,y) > 0{,}8$ et $I_G(x,y) < 0{,}2$ et $I_B(x,y) < 0{,}2$	*(II.6)*
Marron clair	$I_R(x,y) > 0{,}6$ et $0{,}32 < I_G(x,y) < 0{,}72$ et $0{,}05 < I_B(x,y) < 0{,}45$	*(II.7)*
Marron foncé	$0{,}2 < I_R(x,y) < 0{,}6$ et $0{,}06 < I_G(x,y) < 0{,}46$ et $0 < I_B(x,y) < 0{,}33$	*(II.8)*
Bleu-gris	$0{,}2 < I_R(x,y)$ et $0{,}32 < I_G(x,y) < 0{,}72$ et $0{,}34 < I_B(x,y) < 0{,}74$	*(II.9)*
Noir	$I_R(x,y) > 0{,}8$ et $I_G(x,y) < 0{,}2$ et $I_B(x,y) < 0{,}2$	*(II.10)*

où I_R, I_G et I_B sont respectivement les intensités des pixels (x,y) se trouvant à l'intérieur du contour de la lésion dans les composantes Rouge, Verte et Bleue.

II.3.1.3. Caractéristiques de texture

L'analyse de texture a fait l'objet de nombreux travaux de recherche qui ont engendré une multitude de méthodes d'analyse [HAR 73]. Ces méthodes sont basées sur la définition stochastique de la texture, (les matrices de cooccurrence, la fonction d'autocorrélation, les matrices des longueurs de plage, etc) ,sur certaines propriétés géométriques (Les méthodes structurelles, et les polygones de Voronoï), sur des modélisations (champs aléatoires markoviens et fractales) et sur les méthodes de traitement du signal (les moments, les filtres de Gabor, les ondelettes).

Parmi ces méthodes, nous allons présenter par la suite le principe de base de Gabor, LBP (Local Binary Pattern), GLCM (Gray Level Co-Occurrence Matrix) et HOG (Histogram of Oriented Gradient) prises en considération dans la sélection des caractéristiques .

1. Gabor

Les filtres de Gabor permettent de décomposer l'image en composantes correspondant à différentes échelles et orientations [CAL 79][RAH 07]. Ils permettent aussi d'obtenir une localisation conjointe optimale dans le domaine spatial et dans le domaine fréquentiel. Les filtres de Gabor ont été largement appliqués dans de nombreux domaines du traitement d'images tels que la détection des contours, la classification des textures, l'identification des empreintes digitales et constiue un outil performant d'analyse texturale.

Dans le domaine spatial, la fonction de Gabor est une exponentielle complexe, modulée par une fonction gaussienne.

$$G(x,y) = \frac{1}{2\pi\sigma_x\sigma_y} exp\left[-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right)\right] exp[2\pi jWx] \qquad (II.11)$$

W : représente la fréquence de sinusoïdale

$\boldsymbol{\sigma_x}$ et $\boldsymbol{\sigma_y}$: sont les paramètres d'étalement de l'enveloppe gaussienne dans les directions x et y

Dans le domaine fréquentiel, ce filtre est défini par une gaussienne avec des paramètres d'étalement $\boldsymbol{\sigma_u}$ et $\boldsymbol{\sigma_v}$, centrée en **W**:

$$H(u,v) = exp\left\{-\frac{1}{2}\left[\frac{(u-W)^2}{\sigma_u^2} + \frac{v^2}{\sigma_v^2}\right]\right\} \qquad (II.12)$$

avec $\sigma_u = \frac{1}{2\pi\sigma_x}$ et $\sigma_v = \frac{1}{2\pi\sigma_y}$.

Une classe de filtres de Gabor similaires entre eux sera référée par le terme des ondelettes de Gabor. Notons par $\mathbf{G(x,y)}$ l'ondelette mère de Gabor, alors que le banc des filtres similaires entre eux peut être obtenu par les dilations et les rotations appropriées de cette ondelette mère $\mathbf{G(x,y)}$. Les ondelettes de Gabor sont alors définies par:

$$G_{mn}(x,y) = a^{-m}G(x',y'), \quad a > 1, m, n \in N \qquad (II.13)$$

avec

$$x' = a^{-m}(xcos(\theta) + ysin(\theta))$$
$$y' = a^{-m}(-xsin(\theta) + ycos(\theta))$$
$$\theta = \frac{n\pi}{K}$$

K: représente le nombre total des orientations.

a^{-m}: est le facteur d'échelle, son rôle est d'assurer que tous les filtres dans le dictionnaire possèdent la même énergie. Cette énergie est donnée dans le cas continu par:

$$E_{mn} = \iint |G_{mn}(x,y)|^2 dxdy \qquad (II.14)$$

m : est un paramètre d'échelle prenant des valeurs entre 0 et le nombre total d'échelles S.

n: est un paramètre d'orientation prenant des valeurs entre 0 et le nombre total d'orientations K.

2. Local Binary Patern (LBP)

En raison de sa robustesse aux variations d'illumination, de son pouvoir discriminant et de sa simplicité de calcul, l'opérateur de texture Local Binary Pattern (LBP) est devenu une approche populaire dans diverses applications en particulier dans l'analyse des images dans des conditions en temps réel voir figure II.12.

L'idée de base pour le développement de l'opérateur LBP était que les textures de surface bidimensionnelles peuvent être décrites par deux mesures complémentaires : les motifs spatiaux locaux et le contraste de l'échelle des gris. L'opérateur LBP original [OJA 00] forme

des étiquettes pour les pixels de l'image en fixant le seuil du voisinage 3 x 3 de chaque pixel avec la valeur centrale et en considérant le résultat comme un nombre binaire. L'histogramme de ces 2^8 = 256 étiquettes différentes peuvent alors être utilisé comme descripteur de texture. La détermination de la valeur du LBP est obtenue par :

$$LBP = \sum_{p=1}^{p} s(X_i - X_c)2^p \qquad (II.15)$$

où X_c est l'intensité du pixel central, X_i la valeur d'intensité des P pixels voisins considérés et la fonction s (x) est définie par:

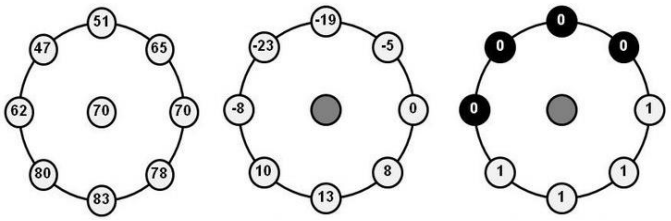

Figure II.12. Calcul du nombre pour LBP

3. Gray Level Co-Occurrence Matrix (GLCM)

Les matrices de cooccurrence caractérisent la distribution spatiale et la nature des niveaux de gris dans une surface limitée. Haralick dans [HAR 73] propose treize caractéristiques de texture différentes, qui sont le résultat d'une matrice de probabilité, qui extrait les caractéristiques des statistiques de texture des images. Ces mesures sont :

Contraste $$Cont = \sum_{n=0}^{G-1} n^2 \left\{ \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P(i,j) \right\}, |i,j| = n \qquad (II.16)$$

G est le nombre de niveau de gris utilisé. Cette mesure de contraste ou de variation locale d'intensité favorise les contributions de P(i,j) qui s'éloignent de la diagonale.

Correlation: $$Corl = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{\{i \times j\} \times P(i,j) - \{\mu_x \times \mu_y\}}{\sigma_x \times \sigma_y} \qquad (II.17)$$

Mesure de la dépendance linéaire du niveau de gris entre les pixels aux positions spécifiées les uns par rapport aux autres

μx, μy, σx et σy sont les moyenne et les standard derivation de Px et Py

Energie (Angular Second Moment (ASM))

$$Energy = \sum_{i=1}^{N}\sum_{j=1}^{N} P(i,j)^2 \qquad \textit{(II-18)}$$

L'ASM est une mesure de l'homogénéité d'une image. Une scène homogène ne contient que quelques niveaux de gris, ce qui donne un GLCM avec des valeurs de P(i,j) peu nombreuses mais relativement élevées. Ainsi, la somme des carrés sera élevée.

Entropy

$$Entropy = \sum_{i=0}^{G-1}\sum_{j=0}^{G-1} P(i,j) \times log(P(i,j)) \qquad \textit{(II.19)}$$

Les scènes inhomogènes ont une faible entropie de premier ordre, alors qu'une scène homogène a une entropie élevée.

Homogénéité

$$H = \sum_{i=1}^{N}\sum_{j=1}^{N} \frac{P(i,j)}{1+(i-j)^2} \qquad \textit{(II-20)}$$

Mesure la proximité de la distribution des éléments dans le GLCM par rapport à la diagonale du GLCM.

Inverse Difference Moment (IDM):

$$IDM = \sum_{i=0}^{G-1}\sum_{j=0}^{G-1} \frac{1}{1+(i,j)^2}\, P(i,j) \qquad \textit{(II.21)}$$

IDM est aussi influcé par l'homogénéité de l'image.

Moyenne

$$Mean(\mu) = \sum_{N}^{j=1} \frac{1}{N}\, P(i,j) \qquad \textit{(II.22)}$$

Il fournit la valeur moyenne des couleurs dans l'image.

Variance

$$E_i = \sum_{i=0}^{G-1}\sum_{j=0}^{G-1} (i-\mu)^2\, P(i,j) \qquad \textit{(II.23)}$$

Cette caractéristique donne un poids relativement élevé aux éléments qui diffèrent de la valeur moyenne de P (i,j).

L'ecart Type(Stddev):

$$Stddev(\sigma) = \sqrt{\left(\frac{1}{N}(P(i,j) - E_i)^2\right)} \qquad (II.24)$$

N est le nombre de pixel totale que l'image contient.

L'écart-type est la racine carrée de la variance de la distribution.

Root Mean Square (RMS):

$$RMS = \sqrt{\left(\frac{1}{n \times m}\sum_{j=0}^{n}\sum_{i=0}^{m}(P(i,j))^2\right)} \qquad (II.25)$$

La RMS est définie comme une sorte de moyenne ou de somme (ou d'intégrale) du carré de l'erreur n, m étant les dimensions de l'image.

Kurtosis (cofficient d'acuité) :

$$kurtosis = \frac{1}{\sigma^4}\sum_{i=0}^{N}(i-\mu)^4\,P(i,j) \qquad (II.26)$$

Il s'agit de mesurer le acuité ou mesure indirecte de l'aplatissement de la distribution par rapport à une distribution normale

Skewnes (coefficient d'asymétrie) :

$$Skewnes = \frac{1}{\sigma^3}\sum_{i=0}^{N}(i-\mu)^3\,P(i,j) \qquad (II.27)$$

C'est la mesure de l'inégalité de la distribution des niveaux d'intensité par rapport à la moyenne.

Dissimalirité

$$Dis = \sum_{i,j=0}^{N-1} P_{i,j}|i-j| \qquad (II.28)$$

Mesure les poids qui eloignent de la diagonale, ansi les poids de dissimilarité augmentent linéairement

4. Histogram of Oriented Gradient (HOG)

L'histogramme de gradients orientés (HOG) est un descripteur de caractéristiques utilisé pour détecter des objets en vision par ordinateur et en traitement d'images. La technique du descripteur HOG compte les occurrences de l'orientation des gradients dans des parties localisées d'une image - fenêtre de détection, ou région d'intérêt (ROI)[RAI 05].

La mise en œuvre de l'algorithme du descripteur HOG est la suivante

- Diviser l'image en petites régions connectées appelées cellules, et pour chaque cellule, calculer un histogramme des directions de gradient ou des orientations de bord pour les pixels à l'intérieur de la cellule.
- Discrétiser chaque cellule en cases angulaires en fonction de l'orientation du gradient.
- Le pixel de chaque cellule apporte un gradient pondéré à sa case angulaire correspondante.
- Les groupes de cellules adjacentes sont considérés comme des régions spatiales appelées blocs. Le regroupement des cellules en un bloc est la base du regroupement et de la normalisation des histogrammes.
- Le groupe d'histogrammes normalisés représente l'histogramme de bloc. L'ensemble de ces histogrammes de blocs représente le descripteur.

II.3.1.4. Mise en échelle des caractéristiques

L'étape de mise en échelle des caractéristiques est nécessaire pour que toutes les caractéristiques soient évaluées sur la même échelle et pour améliorer le résultat de la classification. L'objectif de la mise en échelle est de mettre en échelle toutes les valeurs des caractéristiques dans une plage fixe entre 0 et 1.

La normalisation ou la standardisation sont les deux solutions pour la mise en échelle des caractéristiques utilisées.

1. Normalisation

La méthode Min-Max est une méthode de normalisation la plus utilisée pour la normalisation des valeurs. La normalisation par Min-Max est définie comme suit :

$$Xnorm = \frac{X - Xmin}{Xmax - Xmin} \qquad (II.29)$$

Avec X est la caractéristique à normaliser, Xmin et Xmax sont respectivement les valeurs minimale et maximale de la caractéristique X.

La normalisation par Min-Max représente un inconvénient majeur c'est qu'elle augmente les effets des valeurs aberrantes. Ainsi, avant la normalisation, il est recommandé de traiter les valeurs aberrantes

2. Standardisation

L'objectif de la standardisation est de mettre en échelle les valeurs des caractéristiques tout en prenant en compte l'écart type (standard déviation) des caractéristiques. La transformation par Z-score proposée par [PAT 15]est la méthode la plus utilisée :

$$z = \frac{X - \mu}{\sigma} \qquad (II.30)$$

Avec X est la caractéristique, μ et σ sont respectivement la moyenne et l'écart type de la caractéristique X.

En comparaison avec la méthode Min-Max, Z-score réduit l'effet des données aberrantes.

II.3.2. Ingénierie des caractéristiques

Dans l'étape d'extraction de caractéristiques, il est commode d'extraire le maximum d'information permettant une représentation assez large de chaque image. Cependant, il est nécessaire d'examiner si

- Les caractéristiques extraites sont toutes pertinentes ?
- Il y a des redondances entre les caractéristiques ?
- Les caractéristiques sont elles bruitées ou corrélées ?
- Le grand nombre de caractéristiques ne va-t-il pas impacter le temps d'entrainement, de validation et de test ?

Le fait de considérer un nombre de caractéristiques très élevé pour modéliser et mieux cerner le problème de la classification pourrait induire des difficultés tels que la complexité qui augmente, le temps de calcul qui devient critique et la présence de données bruitées. En effet, une partie de l'ensemble des caractéristiques pourraient être fortement corrélées entre elles et ne fournissent aucune information supplémentaire sur les classes et ne font qu'augmenter le temps du calcul. Alors que les variables indépendantes peuvent être entachées de bruit et ainsi introduire un biais dans le prédicteur et, par conséquent, réduire les performances de la classification. Cela se produit généralement lorsqu'il y a un manque d'informations sur le processus étudié.

Pour ces raisons, la réduction de la dimensionnalité d'un ensemble de données devient de plus en plus nécessaire à travers la prise en compte uniquement des caractéristiques non redondantes et pertinentes. Cela pourrait contribuer à améliorer les performances des classificateurs en réduisant le risque de sur-ajustement.

II.3.2.1. Sélection de caractéristiques

La réduction de la dimensionnalité consiste à trouver une représentation des données initiales dans un espace plus réduit. On distingue deux types de méthodes de réduction de la dimensionnalité ; une réduction basée soit sur une sélection de caractéristiques ou soit sur une transformation des données.

Dans la suite, nous présenterons tout d'abord les méthodes de réduction par une sélection de caractéristiques que nous avons retenues en fonction de leur représentativité dans le domaine.

La sélection de caractéristiques est généralement définie comme un processus de recherche permettant de trouver un sous-ensemble "pertinent" de caractéristiques parmi celles de l'ensemble de départ. La notion de pertinence d'un sous-ensemble de caractéristiques dépend toujours des objectifs et des critères du système.

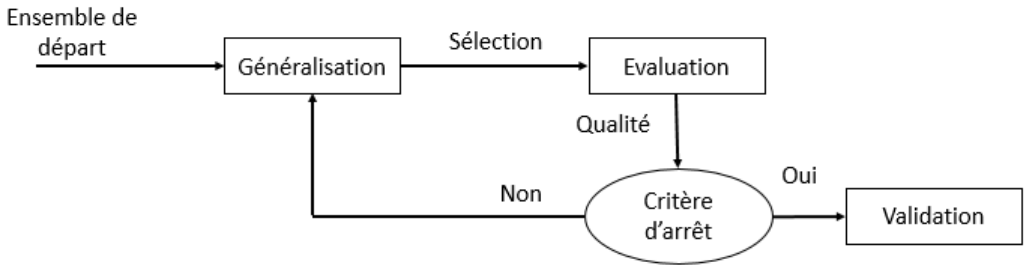

Figure II.13. Procédure générale d'un algorithme de sélection de caractéristiques [CHO 11]

La taille du sous-ensemble à sélectionner peut être prédéfinie et l'algorithme de sélection cherche à trouver le meilleur sous-ensemble de cette taille ou bien non défini a priori dans ce cas il s'agit de chercher le plus petit sous-ensemble dont la performance est plus grande ou égale à un seuil prédéfini. Une autre stratégie peut consister à trouver un compromis entre une bonne performance et une faible taille du sous ensemble.

II.3.2.2. Procédures d'évaluation

Les méthodes utilisées pour évaluer un sous-ensemble de caractéristiques dans les algorithmes de sélection peuvent être classées en trois catégories principales : les méthodes de filtrage « filter », les méthodes enveloppantes « wrapper » et les méthodes intégrées « embedded ».

1. Méthodes de filtrage

Les méthodes de filtrage utilisent des techniques de classement des caractéristiques comme principaux critères de sélection des caractéristiques et elles sont appliquées avant le classification pour filtrer les caractéristiques les moins pertinentes[SAE 07][VIS 15]. Les méthodes de sélection des caractéristiques de filtrage appliquent une mesure statistique pour attribuer un score à chaque caractéristique.

Les caractéristiques sont classées en fonction de cette note et un seuil est utilisé pour éliminer celles qui se situent en dessous de la note seuil. Une propriété fondamentale d'une caractéristique unique est de contenir des informations utiles sur les différentes classes dans

les données. Cette propriété peut être définie comme la pertinence d'une caractéristique qui fournit une mesure de l'utilité de la caractéristique pour discriminer les différentes classes considérées. Ces méthodes sont souvent non variées et considèrent la caractéristique indépendamment ou par rapport à la variable dépendante. Elles peuvent être divisées en deux catégories, celles qui évaluent toutes les caractéristiques en un seul passage et celles qui évaluent plusieurs sous-ensembles de caractéristiques proposées en combinaison avec une recherche heuristique voir figure II.14.

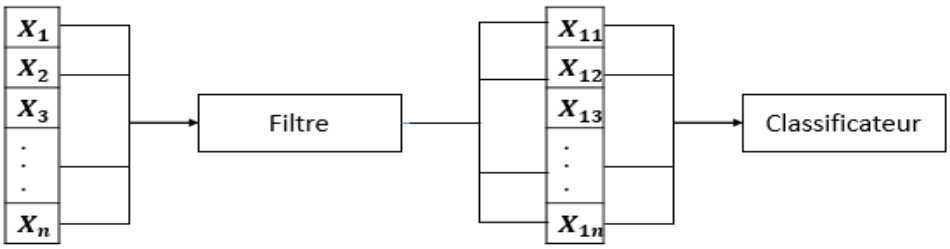

Figure II.14. Procédure du model "filtre" [CHO 11]

Parmi les exemples de méthodes de filtrage, on peut citer le test du Chi carré, le gain d'information.

D'autre part, l'inconvénient des méthodes de filtrage est que le sous-ensemble sélectionné peut ne pas être optimal et qu'il y a de fortes chances qu'un sous-ensemble redondant soit obtenu.

2. Méthodes enveloppantes (Wrapper) :

Dans les méthodes wrapper, nous essayons d'utiliser un sous-ensemble de caractéristiques et de former un modèle en les utilisant. Sur la base des conclusions que nous tirons du modèle précédent, nous décidons d'ajouter ou de supprimer des caractéristiques du sous-ensemble. Le problème est essentiellement réduit à un problème de recherche. Ces méthodes sont généralement très coûteuses en termes de calcul[VIS 15][OLI 14].

Quelques exemples courants de méthodes wrapper sont la sélection de caractéristiques vers l'avant, l'élimination de caractéristiques vers l'arrière, l'élimination de caractéristiques récursives, etc [VIS 15][OLI 14] voir figure II.15.

- Sélection vers l'avant : La sélection directe est une méthode itérative dans laquelle nous commençons par ne pas avoir de caractéristique dans le modèle. À chaque itération, nous continuons à ajouter la caractéristique qui améliore le mieux notre modèle jusqu'à ce que l'ajout d'une nouvelle variable n'améliore pas les performances du modèle.

- Élimination vers l'arrière : Dans l'élimination vers l'arrière, nous commençons par toutes les caractéristiques et supprimons la caractéristique la moins significative à chaque itération, ce qui améliore les performances du modèle. Nous répétons cette opération jusqu'à ce qu'aucune amélioration ne soit observée lors de la suppression des caractéristiques.
- Élimination récursive des caractéristiques : Il s'agit d'un algorithme d'optimisation gourmand qui vise à trouver le sous-ensemble de caractéristiques le plus performant. Il crée des modèles de manière répétée et met de côté la caractéristique la plus performante ou la moins performante à chaque itération. Il construit le modèle suivant avec les caractéristiques de gauche jusqu'à ce que toutes les caractéristiques soient épuisées. Il classe ensuite les caractéristiques en fonction de l'ordre de leur élimination.

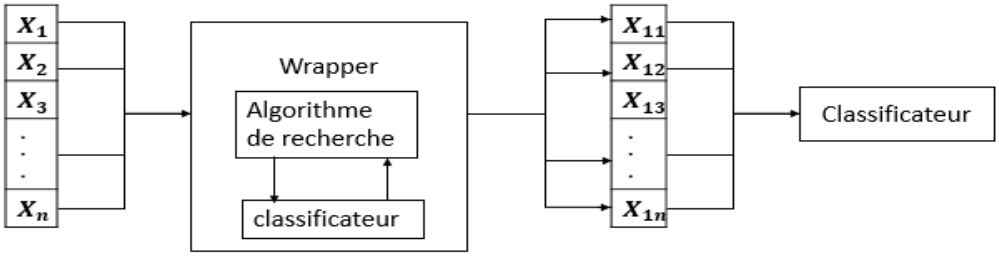

Figure II.15. Procédure du wrapper [OLI 14]

L'une des meilleures façons de mettre en œuvre la sélection de caractéristiques avec les méthodes de wrapper est d'utiliser l'alghorithme Boruta qui trouve l'importance d'une caractéristique en créant des caractéristiques d'ombre[KOH 13][INZ 04].

Il fonctionne selon les étapes suivantes :

1. Il ajoute un caractère aléatoire à l'ensemble de données donné en créant des copies mélangées de toutes les caractéristiques.
2. Il forme un classificateur Random forest sur l'ensemble de données étendu et applique une mesure de l'importance des caractéristiques pour évaluer l'importance de chaque caractéristique, où plus élevée signifie plus importante.
3. À chaque itération, il vérifie si une caractéristique donnée a une plus grande importance que la meilleure de ses caractéristiques d'ombre (c'est-à-dire si la caractéristique a un score Z plus élevé que le score Z maximum de ses caractéristiques d'ombre) et supprime constamment les caractéristiques qui sont jugées très peu importantes.
4. L'algorithme s'arrête soit lorsque toutes les caractéristiques sont confirmées ou rejetées, soit lorsqu'il atteint une limite spécifiée de parcours forestiers aléatoires.

3. Méthodes intégrées (Embedded)

Les méthodes « embedded» (appelées aussi méthodes intégrées) combinent les qualités des méthodes ”wrapper” et ”filter” et incorporent la sélection de variables lors du processus d'apprentissage. Elles sont mises en œuvre par des algorithmes qui ont leurs propres méthodes de sélection de caractéristiques intégrées [AGG 14]. Parmi ces méthodes, on la régression Lasso [ZOU 06] et Bridge [KNI 00], qui comportent des fonctions de pénalisation intégrées pour réduire le suréquipement. Dans les méthodes de sélection de type ”wrapper”, la base d'apprentissage est divisée en deux parties : une base d'apprentissage et une base de validation pour valider le sous-ensemble de caractéristiques sélectionné. En revanche, les méthodes intégrées peuvent se servir de tous les exemples d'apprentissage pour établir le système. Cela constitue un avantage qui peut améliorer les résultats. Un autre avantage de ces méthodes est leur plus grande rapidité par rapport aux approches ”Wrapper” parce qu'elles évitent que le classificateur reprend la procédure du début pour chaque sous-ensemble de caractéristiques.

4. Critère d'Evaluation

Une caractéristique est pertinente si sa suppression entraine une baisse des performances du système de classification. Le meilleur sous-ensemble de caractéristiques est obtenu selon le critère d'évaluation adopté qui permet de mesurer quantitativement la qualité d'une caractéristique ou d'un sous-ensemble généré par la procédure de recherche choisie [DAS 97]. Les critères d'évaluation généralement utilisées sont les suivants : mesure de distance, mesure d'information, mesure de dépendance ou de corrélation et mesure de l'erreur de classification.

5. Critère d'arrêt

Certains critères doivent être définis pour arrêter le processus de recherche sur les sous-ensembles de caractéristiques. Pour les méthodes de filtrage, le critère d'arrêt couramment utilisé est basé sur l'ordre des caractéristiques, rangées selon certains scores de pertinence (généralement des mesures statistiques). Une fois les caractéristiques ordonnées, celles qui ont les scores les plus élevés seront choisies et utilisées par un classificateur. Pour les méthodes de type ”wrapper”, le processus de recherche peut s'arrêter lorsque il n'y a plus d'amélioration de précision. En d'autres termes, lorsqu'il n'y a plus la possibilité de trouver un sous-ensemble meilleur que le sous-ensemble actuel. Un critère d'arrêt pour les méthodes enveloppantes est de continuer à rechercher jusqu'au moment ou` la précision dépasse un certain seuil défini par l'utilisateur.

II.3.2.3. Procédure de sélection

De nombreux algorithmes ont été proposés dans la littérature et des travaux sont encore en cours pour proposer de nouvelles approches de sélection. Les algorithmes de sélection de caractéristiques les plus utilisés sont [ANI 14][FIL 18]. :

1. Relief :

Relief est la méthode de filtrage la plus connue pour la sélection de caractéristiques, développé par Kira et Rendell en 1992 [KIR 92]. RelieF tente de déterminer le plus proche voisin d'un certain nombre d'échantillons sélectionnés au hasard à partir de l'ensemble de données. Pour chaque échantillon sélectionné, les valeurs des caractéristiques sont comparées à ceux des voisins les plus proches et les scores pour chaque caractéristique sont mis à jour. L'idée est d'estimer la qualité des attributs en fonction de la qualité de leurs valeurs et faire la distinction entre des échantillons proches les uns des autres. Il est particulièrement sensible aux interactions entre les caractéristiques.

Son principe est de calculer une mesure globale de la pertinence des caractéristiques en accumulant la différence des distances entre des exemples d'apprentissage choisis aléatoirement et leurs plus proches voisins de la même classe et de l'autre classe.

Sa mise en œuvre est simple et facile cependant, sa technique aléatoire ne peut pas garantir la cohérence des résultats lorsqu'on applique plusieurs fois la méthode sur les mêmes données.

Algorithme de sélection de Relief

Entrées: Une base d'apprentissage $A = \{X_1, X_2, .., X_M\}$ *où chaque exemple* $X_i = \{x_{i1}, x_{i2}, .., x_{iN}\}$

Nombre d'itérations T

Sorties: $W[N]$ *: vecteur de poids des caractéristiques* (f_i), $-1 \leq W[i] \leq 1$

$\forall i, W[i] = 0;$

Pour $t = 1$ *à* T *Faire*

  Choisir aléatoirement un exemple X_k

  Chercher deux plus proches voisins (un dans sa classe (X_a) *et un deuxième dans l'autre classe* (X_b)*)*

Pour $i = 1$ *à* N *Faire*

$W[i] = W[i] + |xki - xbi| - |xki - xai|$

Fin Pour

Fin Pour

Retourner W

2. Correlation Feature Selection (CFS) :

Cet algorithme qui appartient à la famille des méthodes de filtrage, tente de trouver un ensemble de caractéristique individuellement bien corréler avec la classe, mais qui ont une petite inter corrélation entre eux [HAL 99]. Il est simple à mettre en œuvre et ne nécessite pas un temps de calcul important. Le critère de corrélation basé sur coefficient de Pearson est utilisé pour évaluer le degré de ressemblance entre deux caractéristiques.

Coefficient de Pearson

$$R(i) = \frac{cov(X_l, Y)}{\sqrt{var(X_l)var(Y)}} \qquad (II.31)$$

avec Covariance

$$cov(X_l, Y) = \sum_{i=1}^{l} (x_i - \overline{x})(y_i - \overline{y}) \qquad (II.32)$$

Variances

$$var(Y_l) = \sum_{i=1}^{l} (x_i - \overline{y})^2 \quad var(X_l) = \sum_{i=1}^{l} (x_i - \overline{x})^2 \qquad (II.33)$$

moyennes

$$\overline{x} = \sum_{i=1}^{l} x_i \qquad \overline{y} = \sum_{i=1}^{l} y_i \qquad (II.34)$$

3. Chi2 :

C'est un algorithme de sélection des caractéristiques qui appartient à la famille des algorithmes de filtrage basé sur la statistique χ^2 . Cette méthode mesure l'écart à l'indépendance entre une caractéristique et une classe. Elle commence par un niveau de signification élevé pour toutes les caractéristiques pour la discrétisation et chaque caractéristique est triée en fonction de ses valeurs.

4. Elimination récursive de caractéristiques (Recursive Feature Elimination, RFE)

C'est une méthode de cartographie basée sur l'idée à plusieurs reprises, construire un modèle et choisir le meilleur ou le pire performant. Cette méthode qui appartient aux méthodes de filtrage est souvent utilisée comme étape de prétraitement pour les méthodes intégrée (souvent avec l'algorithme de classification SVM) afin de la généraliser à des grandes masses de données [GUY 08].

La procédure de sélection est décrémentale et élimine progressivement les caractéristiques de faible poids. A chaque récursion de l'algorithme SVM-RFE, la caractéristique possédant le score le plus faible est éliminé (Backward Selection). Le processus est arrêté lorsque le nombre de caractéristiques restantes est atteint.

L'algorithme est décomposé en trois étapes :

Tant qu'il reste des caractéristiques,

- Entrainer le classifieur SVM (linéaire)
- Calcul des poids wi2
- Supprimer la (les) caractéristiques correspondantes aux poids les plus faibles.

La procédure est grandement accélérée lorsque plusieurs caractéristiques sont éliminées simultanément.

5. Algorithme génétique (GA)

Les algorithmes génétiques (AG) sont des méthodes d'optimisation stochastique, faisant partie des méta-heuristiques qui s'inspirent des mécanismes d'évolution des populations biologiques. Ils utilisent la notion de sélection naturelle appliquée à une population de solutions potentielles au problème donné [KAN 18][SRI 18] leur fonctionnement est basé sur les étapes suivantes

Initialisation : Générer aléatoirement une population initiale de taille N chromosomes.

Évaluation : Évaluer chaque individu de la population par la fonction d'évaluation appropriée au problème.

Reproduction : Créer une nouvelle population de N chromosomes par l'utilisation d'une méthode de sélection appropriée et l'application d'opérateurs génétiques (croisement et mutation) sur certains chromosomes au sein de la population courante.

Retour à l'étape 2 tant que la condition d'arrêt du problème n'est pas satisfaite.

La sélection des individus s'effectue le plus souvent sur la base de leur fonction d'évaluation. Dans le croisement, les chromosomes échangent des séquences de gènes entre eux. Il est chargé de construire un individu (ou une solution) qui soit le mélange de plusieurs solutions. La mutation est définie comme étant la modification aléatoire de la valeur d'un gène dans un chromosome. Cette opération évite une convergence vers les optima locaux.

Les algorithmes génétiques (AG) ont aussi été utilisés dans le domaine de la sélection de caractéristiques afin d'accélérer la recherche et d'éviter les solutions avec les optima locaux. Ce type de sélection des caractéristiques fait partie des méthodes enveloppes (Wrapper) a fait preuve de son efficacité pour résoudre des problèmes d'optimisation dont l'espace de recherche est de grande dimension.

II.3.3. Evaluation des performances

Pour l'implémentation nous avons choisi d'utiliser comme algorithme de classification le SVM avec le RBF comme kernel. D'autres études sur le choix de l'algorithme de classification seront présentées dans le chapitre suivant. Pour l'évaluation de la pertinence des

caractéristiques extraites nous allons utiliser les valeurs de précision de classification et la matrice de confusion.

II.3.3.1. Etude préliminaire

Cette première étude concerne la détermination des valeurs optimales de l'échelle et l'orientation qui donne le meilleur taux de classification en considérant seule la caractéristique texture par application du filtre de Gabor. Les résultats de la simulation pour différents nombres d'échelles et de directions (La figure II.16) montrent que la meilleure précision correspond à une échelle et une orientation dont les valeurs sont respectivement égales à 3 et 8.

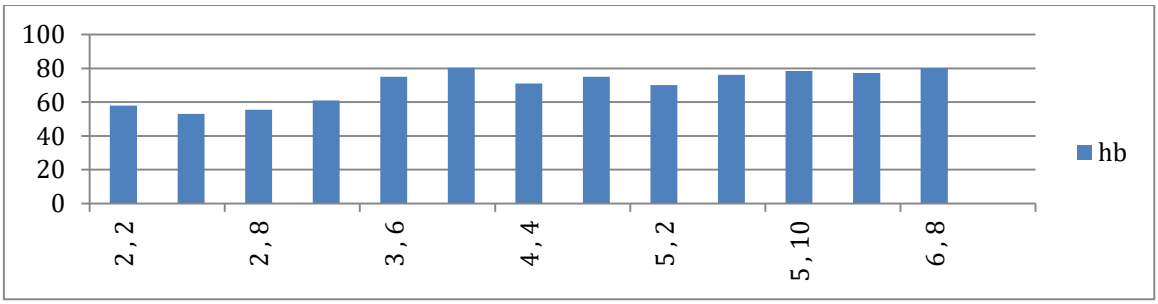

Figure II.16. Différentes échelles du filtre de Gabor

Une seconde étude traite de l'impact des caractéristiques de texture sur la précision de classification. Les caractéristiques extraites sont :

- 13 caractéristiques à partir de la matrice GLCM,
- 96 caractéristiques pour le filtre de Gabor,
- 59 caractéristiques pour le LBP et
- 34596 caractéristiques pour le HOG.

Le tableau II.3 présente la précision de classification pour chaque caractéristique texture utilisant la base de données « Atlas dermoscopie »

Tableau. II.3. Résultat de classification

	Gray Level Co-Occurrence Matrix	*Filtre de Gabor*	*Histogramme de gradient orienté*	*Motif binaire Local*
Exactitude (%)	*80.00*	*83.00*	*80.23*	*81.23*

On remarque bien d'après les valeurs exactitude de la classification présentée sur le tableau II. 3 que la meilleure exactitude est obtenue par le filtre de Gabor avec un taux égale à 83,00%.

Par la suite, nous allons procéder à l'extraction des caractéristiques couleur et forme et procéder à nouveau à l'évaluation de notre modèle de classification. Le tableau II.4 présente les exactitudes de classification utilisant séparément les caractéristiques de type Couleur, Texture, forme et squelette.

Tableau. II.4. Exactitude des différentes caractéristiques

	Couleur	*Texture*	*Forme*	*Squelette*	*Fusion*
Exactitude (%)	*65.03*	*82.02*	*87.00*	*90.26*	*91.50*

D'après les résultats présentés sur le tableau II.4 on peut conclure que les caractéristiques couleurs utilisées ne sont pas très pertinentes. Par contre l'utilisation des caractéristiques forme et surtout les nouvelles caractéristiques issues de la squelettisation ont permis une amélioration nette de l'exactitude de classification. La concaténation de l'ensemble des caractéristiques nous a permis d'atteindre un taux de classification égale à 91.50%. Cette amélioration reste encore faible et nous a poussé à améliorer encore notre approche proposée.

II.3.3.2. Résultats des simulations

L'utilisation de l'ensemble des caractéristiques extraites nous a permis d'avoir un taux de classification égale à 91,50 et qui reste inférieur à nos attentes. 34764 caractéristiques ont été utilisées et toujours les questions qui se posent : est-ce que toutes ces caractéristiques sont pertinentes, est ce qu'elles ne représentent pas de doublons, et est ce qu'elles ne sont pas corrélées. Pour répondre à toutes ces questions et pour améliorer d'avantage notre approche de classification proposée nous allons procéder à une sélection de caractéristiques.

Il est à noter que toutes les caractéristiques (texture, couleur, forme et squelette) sont concaténées et ont été normalisées utilisant la méthode Z-score.

5 algorithmes ont été sélectionner et définis comme étant les algorithmes les plus utilisés pour la sélection des caractéristiques. Ici nous allons mener une première étude pour voir lequel de ces 5 algorithmes de sélection et le mieux adapté à notre cas d'utilisation. Nous avons utilisé pour cette partie les deux bases de données ISIC[COD 18] et Ph2 [MEN 13] et comme algorithme de classification le SVM avec la RBF comme kernel.

Le résultat de la sélection des caractéristiques utilisant les 5 algorithmes est présenté dans les tableaux II.5 et II.6.

Tableau. II.5. Caractéristiques sélectionnées avec les 4 différents algorithmes de sélection

	Algorithmes de sélection	*Caractéristiques sélectionnées*	
		N°	*Caractéristiques*
PH2	*GA*	*6*	*Sous-branche du squelette, nombre de branches , Contraste, Corrélation, taille du squelette et couleur marron clair*
	RFE	*5*	*Longueur du squelette, nombre de couleurs, IDM, RMS et couleur marron clair*
	RelieF	*6*	*Sous-branche du squelette, nombre de branches, Rapport largeur/longueur, IDM, Couleur marron clair et Nombre de couleurs*
	CFS	*6*	*Taille du squelette, Nombre de paramètres, Nombre de sous-branches du squelette, Poids du squelette, Nombre de couleurs et RMS*
	Chi2	*4*	*Nombre de branches, Rapport largeur/longueur, Nombre de couleurs et Contraste*
ISIC	*GA*	*5*	*Taille du squelette, Nombre de sous-branches du squelette, longueur du squelette et RMS*
	RFE	*4*	*Longueur du squelette, nombre de paramètres, RMS et couleur marron clair*
	RelieF	*5*	*Taille du squelette; Rapport entre la largeur et la longueur du squelette, Nombre de branche, Variance et couleur marron clair*
	CFS	*4*	*Taille du squelette, Nombre de sous-branches du squelette, Nombre de couleurs et RMS*
	Chi2	*3*	*Nombre de branches, Rapport largeur/longueur, et Nombre de couleurs*

On remarque que tous les algorithmes de sélections de caractéristiques ont permis de réduire significativement le nombre de caractéristiques pour les deux bases de données. Pour évaluer cette sélection, le tableau II .6 présente les taux de classification des deux bases de données utilisant seulement les caractéristiques sélectionnées par chaque algorithme.

D'après les résultats de sélection de caractéristiques présentés dans le tableau II .6 on peut noter que la meilleur exactitude de classification est obtenue avec les caractéristiques sélectionnées par l'algorithme RelieF (sous-branche du squelettique, nombre de branches, rapport de largeur/longueur, IDM, couleur marron clair et nombre de couleurs), ce qui implique que les nouvelles caractéristiques basées sur le squelette sont très importantes et peuvent améliorer les résultats de la classification du cancer de peau.

Tableau. II.6. Résultat de la sélection de caractéristiques

	Nombre de Caractéristiques	*Exactitude (%)*	*Algorithme de sélection*	*Nombre de caractéristiques sélectionnées*	*Exactitude (%)*
Ph2	*34828*	*91.50*	*GA*	*6*	*93.22*
			RFE	*5*	*92.80*
			RelieF	*6*	*96.50*
			CFS	*6*	*94.00*
			Chi2	*4*	*85.26*
ISIC	*34828*	*80.03*	*GA*	*5*	*80.01*
			RFE	*4*	*71.10*
			RelieF	*5*	*82.00*
			CFS	*4*	*72.50*
			Chi2	*3*	*72.50*

Ce résultat confirme notre supposition de départ : un grand nombre de caractéristiques extraites ne permet pas toujours une meilleure classification. Avec seulement 6 caractéristiques, nous avons pu obtenir un taux de classification égale à 96.50%pour la base PH2 contre 91.50% avec 34764 caractéristiques. Et pour la base ISIC, nous avons obtenu une exactitude de classification égale à 82.00% avec seulement 5 caractéristiques (Taille du squelette; Rapport entre la largeur et la longueur du squelette, Nombre de branche, Variance et couleur marron clair) contre 80.03% avec 34764 caractéristiques.

La matrice de confusion est aussi utilisée pour évaluer notre approche de classification proposée à travers l'évaluation du taux d'erreur de la classification et ainsi nous renseigner sur le taux des faux négatifs (le nombre de lésion de type mélanome classées comme étant non-mélanome.) On remarque que d'après les résultats de la matrice de confusion présentée sur le tableau II.7 que seulement 21 lésions mélanome ont été faussement classées comme étant non-mélanome. Ce chiffre qui est très grand n'est pas du tout acceptable et nous a poussé à améliorer encore notre approche proposée.

Tableau. II.7. Matrice de confusion

	Mélanome	*Non-mélanome*
Mélanome	*378*	*21*
Non-mélanome	*14*	*587*

Pour situer notre approche proposée, nous allons mener une étude comparative avec quelques approches de la littérature. A noter cette comparaison est effectuée utilisant les deux bases de données Ph2 et ISIC. Le tableau II.8 présente les résultats de notre approche

proposée en comparaison avec les approches proposées respectivement par Immagulate [IMM 15], Dalila [DAL 17], et Waheed [WAH 17].

Tableau. II.8. Etude comparative de la classification utilisant la base de données Ph2 utilisant différents algorithmes de la littérature

Approches	*Caractéristiques utilisées*	*Sélection de caractéristiques*	*Algorithme de classification*	*Exactitude*
Filali [FIL 19b]	*Squelette, Couleur, Texture*	*Oui*	*SVM*	*96.50*
Dalila [DAL 17]	*Propriété Géométrique, texture et couleur*	*Oui*	*ANN*	*86.60*
Dalila [DAL 17]	*Propriété Géométrique, texture et couleur*	*Oui*	*KNN*	*85.22*
Immagulate [IMM 15]	*Couleur et texture*	*Non*	*SVM*	*85.00*
Waheed [WAH 17]	*Couleur dans HSV et RGB, texture en utilisant le GLCM*	*Non*	*SVM*	*88.20*
Filali [FIL 19a]	*GLCM, Gabor filter, LBP, HOG, couleur et Asymmetrie.*	*Non*	*SVM*	*90.30*

D'après les résultats présentés sur le tableau II.8 on peut constater d'abord que les caractéristiques que nous avons proposées nous ont permis d'avoir une exactitude de classification supérieure aux approches utilisées dans cette étude comparative. Aussi, avec la sélection des caractéristiques nous avons pu améliorer encore cette précision et dépasser de loin les autres approches.

Il faut signaler que les approches avec lesquelles nous avons mené cette étude comparative utilisent l'apprentissage automatique et non pas l'apprentissage profond.

II.4. Conclusion

La première partie de ce chapitre a été consacrée à la segmentation des images dermoscopiques des lésions cutanées qui constitue une étape cruciale dans le processus de classification des images des lésions cutanées utilisant l'apprentissage automatique. Une bonne segmentation implique une meilleure identification et détection de la lésion. Plusieurs algorithmes de segmentation sont proposés dans la littérature pour la segmentation des lésions cutanées. Dans ce contexte, nous avons proposé de procéder à un prétraitement utilisant la décomposition multi-échelle par le biais des EDP qui permet de séparer l'image

initiale en deux composantes ; composante « texture » et composante « objet ». La segmentation est effectuée sur la composante objet. Les résultats de simulation ont montré la robustesse de l'approche proposée dans le sens où les performances du plus simple des algorithmes de segmentation s'améliorent nettement.

Les caractéristiques sont extraites séparément à partir du masque de la lésion obtenue par l'approche de segmentation proposée et les deux images issues de la décomposition. Ainsi, les caractéristiques de texture seront extraites de la composante texture, les caractéristiques de forme et de couleur ont été extraites de la composante objet. Nous avons proposé de nouvelles caractéristiques de forme qui offre pour une meilleure description du squelette du masque de la lésion [FIL 19b]. en effet , la forme de la lésion est le plus important paramètre pris en considération dans le diagnostic du mélanome. Une lésion dont le bord présente des irrégularités est souvent classifiée comme étant mélanome ; il est alors indispensable de disposer de caractéristiques saillantes.

Dans la seconde partie porte sur la réduction de dimensionnalité. D'abord, les différents composants nécessaires à une procédure de sélection de caractéristiques, ont été décrits. Ensuite, nous avons effectué, une étude comparative avec différentes procédures de sélection afin d'obtenir la sélection optimale qui conduit à une augmentation de la précision des prédictions.

Chapitre III :
Classification des lésions cutanées basée sur l'apprentissage automatique

III.1 Introduction

La classification est la dernière étape dont l'objectif est de concevoir un modèle capable de classer une nouvelle image de lésion cutanée en mélanome ou non mélanome en fonction de leurs caractéristiques extraites, normalisées et sélectionnées. Dans la littérature, de nombreuses approches de classification du cancer de la peau ont été proposées [CEL 07][OZK 17][NAS 18], Arbres de décision (Decision Tree, AD), Régression logistique, k plus proches voisins (K-Nearest Neighbors , KNN) et les machines à vecteurs de support (Support Vector Machine, SVM). Cependant, chaque algorithme de classification classifie correctement quelques lésions où d'autres échouent. Pour remédier à cet inconvénient, il s'avère utile de combiner plusieurs modèles classification en un seul classificateur ensembliste.

Dans ce contexte, ce chapitre présente dans une première partie une étude comparative entre les meilleurs algorithmes de classification utilisés dans la classification des lésions cutanées. La deuxième partie est consacrée à la classification ensembliste (Ensemble Learning).

III.2 Algorithmes de classification

III.2.1 Régression logistique

La régression logistique est un algorithme qui construit un hyperplan de séparation entre deux ensembles de données, en utilisant la fonction logistique pour exprimer la distance de l'hyperplan comme une probabilité d'appartenance à une classe. La régression logistique est largement utilisée dans les applications médicales pour la facilité avec laquelle les paramètres du modèle peuvent être interprétés comme des changements de cotes logarithmiques, pour les méthodes de sélection de variables qui sont souvent disponibles dans les applications commerciales, et pour permettre l'interprétation des résultats en tant que probabilités. Bien que le modèle soit à paramètres linéaires et ne puisse donc calculer que des limites de décision linéaires, il est néanmoins un modèle prédictif largement utilisé dans les applications médicales [DRE 01][KHA 19b].

Les principaux avantages de cette méthode par rapport aux autres algorithmes sont sa facilité d'utilisation (elle est implémentée dans de nombreux logiciels), permettant l'interprétation des résultats sous forme de probabilités. Néanmoins, il est souhaitable d'éliminer les variables d'entrée qui ne contribuent qu'à des corrélations aléatoires au résultat global. En 2000 les [DRE 00] ont montré, dans une étude comparative, que la régression logistique s'effectue à peu près au même niveau que les réseaux neuronaux artificiels et les machines à vecteurs de support, qui sont tous deux capables de mettre en œuvre des surfaces de séparation non linéaires.

III.2.2Arbre de décision

Un arbre de décision est une technique de classification qui se concentre sur une forme de représentation facilement compréhensible, et constitue l'une des méthodes d'apprentissage les plus courantes. Les arbres de décision utilisent des ensembles de données qui se composent de vecteurs d'attributs, qui à leur tour contiennent un ensemble d'attributs de classification décrivant le vecteur et un attribut de classe assignant l'entrée de données à une certaine classe [LUK 15].

Un arbre de décision est construit en divisant itérativement l'ensemble de données sur l'attribut qui sépare le mieux possible les données dans les différentes classes existantes jusqu'à ce qu'un certain critère d'arrêt soit atteint. La forme de représentation permet aux utilisateurs d'avoir un aperçu rapide des données, puisque les arbres de décision peuvent être facilement visualisés dans un format structuré en arbre, qui est facile à comprendre pour l'homme[VIC 17][KOK 17].

L'un des premiers algorithmes concernant la création d'arbres de décision a été le Dichotomis itératif 3 (DI3) en 1986 et son successeur, l'algorithme C4.5 en 1993, tous deux développés par Ross Quinlan [QUI 86]. Ces algorithmes ont constitué la base de nombreux développements ultérieurs[HSS 14][ROK 14].

Les arbres de décision sont des arbres dirigés, qui sont utilisés comme outil d'aide à la décision. Ils représentent des règles de décision et illustrent des décisions successives.

Dans les arbres de décision, les nœuds peuvent être séparés en nœud racine, nœuds internes et nœuds terminaux, également appelés feuilles. Le nœud racine représente le début du processus d'aide à la décision et n'a pas de bord entrant. Les nœuds internes ont exactement un bord entrant et au moins deux bords sortants (voir figure III.1).

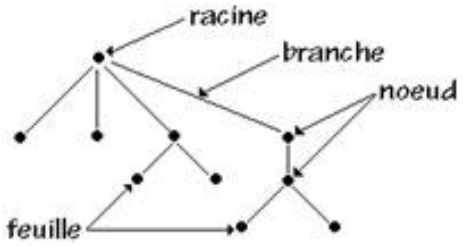

Figure III.1. Exemple d'arbre de décision

L'entrainement d'un arbre de décision est une méthode commune d'exploration de données qui est principalement utilisée à des buts de classification. Son but est de prédire la valeur d'un attribut cible, sur la base d'un certain nombre d'attributs d'entrée. L'entraînement d'un arbre de décision dans un environnement supervisé se fait en utilisant un ensemble d'entraînement pour trouver des modèles dans les données et construire l'arbre de décision.

Ensuite, un ensemble d'exemples inédits peut être utilisé pour prédire la valeur de l'attribut cible.

On représente l'ensemble d'entrainement par la formule suivante :

$$(\vec{x}, Y) = (x_1, x_2, x_3, \dots, x_n, Y) \qquad (III.1)$$

avec $\vec{x}$ étant un vecteur contenant n valeurs d'entrée, où n est le nombre d'attributs dans l'ensemble de données, et Y la valeur de l'attribut cible.

Pour former un arbre de décision et créer ainsi un classificateur, il faut un ensemble de caractéristiques contenant un attribut cible, des attributs d'entrée, un critère de séparation et un critère d'arrêt. À un nœud donné, le critère de séparation calcule une valeur pour tous les attributs. Cette valeur représente une mesure de la quantité d'informations obtenues en divisant le nœud à l'aide de cet attribut. Ensuite, la meilleure valeur de tous les attributs est prise et le nœud est divisé en différents résultats de l'attribut respectif. À ce stade, le processus de recherche de la meilleure division parmi les attributs est appliqué récursivement à tous les sous-arbres générés jusqu'à ce qu'un critère d'arrêt soit atteint.

III.2.3 Réseaux Bayésiens

Les réseaux bayésiens sont constitués de nœuds et de connexions dirigées entre ces nœuds qui symbolisent les dépendances entre eux. Ce sont des modèles graphiques acycliques dirigés probabilistes. Chaque nœud représente un attribut d'intérêt pour la tâche donnée[NGU 13][BAS 13].

Le réseau bayésien le plus fondamental s'appelle Naïf Bayes et la raison pour laquelle il est appelé Naïf est que ce réseau suppose qu'il n'y a pas de liens de dépendance entre les attributs. Ce n'est presque jamais le cas dans les tâches pratiques d'exploration de données et cette méthode a donc tendance à obtenir de moins bons résultats que des algorithmes plus détaillés. Les réseaux bayésiens normaux utilisent des données connues pour estimer les dépendances entre les attributs et l'étiquette de classe et utilisent ces informations pour calculer les probabilités de différents résultats possibles d'événements futurs. Il applique automatiquement le théorème de Bayes à des problèmes complexes et est donc en mesure d'acquérir des connaissances sur l'état des attributs et leurs dépendances.

$$P(A|B) = \frac{P(B|A) * P(A)}{P(B)} \qquad (III.2)$$

Où

A et B sont deux évènements.

P(B) : la probabilité que l'évènement B se produit

$P(A|B)$: une probabilité conditionnelle pour qua A se produit à condition que B soit vrai.

III.2.4 Machines à vecteurs de support

Les machines à vecteurs de support (Support Vector Machine, SVM) est un algorithme qui appartient au domaine des techniques d'apprentissage supervisées et donc ont besoin de données connues et étiquetées pour classer les nouvelles données. L'approche de base pour la classification commence par essayer de créer une fonction qui divise les points de données en étiquettes correspondantes avec (Z1) le moins d'erreurs possibles ou (Z2) la plus grande marge possible[NOB 06][FRE 13].

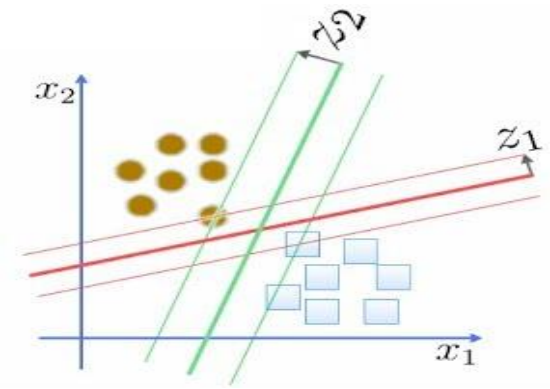

Figure III.2. Visualisation d'une machine à vecteur de support divisant un ensemble de données en deux classes, en utilisant deux séparations linéaires différentes.

En théorie, les machines à vecteurs support créent un ou plusieurs hyperplans dans un espace n-dimensionnel. La première tentative dans le processus de division des données est toujours, d'essayer de séparer linéairement les données dans les étiquettes correspondantes figure III. 2.

Par exemple, pour une tâche de prédiction du cancer de la peau on utilise un ensemble de données comportant n points de données, où chaque point de données est constitué d'une étiquette y ∈ {mélanome, non-mélanome} et d'un vecteur d'attribut ($\vec{x}$) contenant les valeurs des données pour cette session spécifique. La machine à vecteurs de support essaie maintenant de trouver une fonction qui sépare tous les points de données ($\vec{x}$, y) avec y = oui de tous les points de données ($\vec{x}$, y) avec y = non.

Si les données sont entièrement séparables de manière linéaire, la fonction résultante peut être utilisée pour classer les événements futurs. Steinwart et Christman [STE 08] mentionnent deux préoccupations principales, concernant cette approche.

Les données peuvent ne pas être bien ou pas du tout séparables linéairement, ce qui est souvent le cas pour les données du monde réel. Il peut arriver d'avoir des exemples qui se comportent de manière tout à fait similaire, avec un vecteur d'attributs différent.

Une autre préoccupation de l'SVM est la possibilité de le sur-ajuster. Pour éviter cela, les données doivent être prétraitées pour identifier le bruit et accepter certaines erreurs de

classification. Dans le cas contraire, les valeurs de précision du SVM seront erronées et entraîneront une classification plus erronée pour les événements futurs.

III.2.5 Apprentissage basé sur les instances

L'apprentissage par instance décrit le processus de résolution de problèmes basé sur les solutions de problèmes similaires déjà connus, également connu sous le nom d'apprentissage du voisin le plus proche [VIC 17][MUR 19]. Chaque système d'apprentissage par instance nécessite un ensemble de paramètres :

- Une fonction de distance qui mesure la similarité entre les problèmes ou les entrées de données. Cette fonction est nécessaire pour mesurer quels sont les voisins les plus proches du nouveau problème.
- Un certain nombre de voisins qui sont pris en compte lors de la résolution du nouveau problème.
- Une fonction de pondération qui permet de quantifier davantage les voisins trouvés afin d'augmenter la qualité de la prédiction et de l'apprentissage.
- Une méthode d'évaluation qui décrit une fonction sur la façon d'utiliser les voisins trouvés pour résoudre le problème donné.

Les méthodes d'apprentissage basées sur les instances font partie des méthodes d'apprentissage paresseux, ce qui signifie qu'aucun calcul n'est effectué sur les données avant qu'une requête ne soit donnée au système. Ces méthodes se distinguent des méthodes d'apprentissage paresseux telles que les arbres de décision, qui tentent de structurer les données avant de recevoir les requêtes.

III.2.6 Réseau de neurones artificiels

Singh et Chauhan [SIN 10] définissent les réseaux neuronaux artificiels comme "un modèle mathématique qui est basé sur des réseaux neuronaux biologiques et qui est donc une émulation d'un système neuronal biologique". Par rapport aux algorithmes conventionnels, les réseaux de neurones peuvent résoudre des problèmes plutôt complexes, à un niveau nettement plus facile en termes de complexité algorithmique. Par conséquent, la principale raison d'utiliser les réseaux neuronaux artificiels est leur structure simple et leur nature auto-organisatrice qui leur permet de traiter un large ensemble de problèmes sans aucune autre intervention de l'humain.

Un réseau de neurones artificiels (RNA)[MAT 15] se compose de nœuds, également appelés neurones, de connexions pondérées entre ces neurones qui peuvent être adaptées pendant le processus d'apprentissage du réseau et d'une fonction d'activation qui définit la valeur de sortie de chaque nœud en fonction de ses valeurs d'entrée. Chaque réseau neuronal est constitué de différentes couches. La couche d'entrée reçoit des informations de sources externes, telles que les valeurs d'attribut de l'entrée de données correspondante, la couche de

sortie produit la sortie du réseau et des couches cachées relient la couche d'entrée et la couche de sortie entre elles. La valeur d'entrée de chaque nœud dans chaque couche est calculée par la somme de tous les nœuds entrants multipliée par le poids respectif de l'interconnexion entre les nœuds. En outre, les réseaux neuronaux peuvent être divisés en deux types principaux :

Les réseaux Feedforward : sont définis comme tous les réseaux qui ne bénéficient pas d'un retour d'information de la part du réseau lui-même. Cela signifie que les données d'entrée circulent dans un sens, des nœuds d'entrée vers les nœuds de sortie en passant par 0 à n nœuds cachés. Aucune information n'est donnée à l'envers pour réadapter le système.

Les réseaux récurrents sont définis comme tous les réseaux qui contiennent une option de retour d'information et sont donc capables de réutiliser les données des étapes ultérieures pour le processus d'apprentissage des étapes précédentes.

La valeur de sortie de chaque nœud est calculée en utilisant toutes les valeurs d'entrée sur une fonction prédéfinie qui est la même pour chaque nœud du réseau. La fonction la plus couramment utilisée est la fonction sigmoïde (0_j), qui est définie comme suit :

$$o_j = \frac{1}{1 + e^{-ij}} \qquad (III.3)$$

où $i_j$est la somme des nœuds d'entrée de j.

Les deux principaux avantages de cette fonction sont sa normalisation à des valeurs comprises entre 0 et 1 et sa nature non linéaire, qui permet un apprentissage rapide plus facile du réseau et la prévention des effets de surcharge et de domination. Un effet de domination se produit lorsqu'un ou plusieurs attributs ont une très forte influence sur l'attribut cible prévu, ce qui rend les autres attributs insignifiants et les rend donc dominants. Dans un scénario d'apprentissage supervisé, les réseaux neuronaux artificiels peuvent être formés en utilisant l'algorithme de rétro-propagation, qui réajuste les poids des interconnexions dans le réseau neuronal en fonction des taux d'erreur locaux.

La rétro-propagation dans les réseaux neuronaux décrit le processus d'utilisation d'une erreur locale pour réajuster les poids des interconnexions dans le réseau neuronal. Explicitement, cela signifie qu'après avoir fait une prédiction pour un ensemble de valeurs d'entrée, la valeur réelle de la production est comparée à la valeur de prédiction et une erreur est calculée. Cette erreur est ensuite utilisée pour réajuster les poids des connexions en commençant par les bords qui sont directement connectés aux nœuds de sortie du réseau, puis en allant plus loin dans celui-ci.

Pour former un réseau de neurones, il est important de comprendre les principaux paramètres qui peuvent être utilisé pour optimiser le processus d'apprentissage :

- Le taux d'apprentissage spécifie la vitesse à laquelle le processus d'apprentissage est effectué. La valeur du paramètre se situe entre 0 et 1 et est multipliée par l'erreur locale pour chaque valeur de sortie. Par conséquent, un taux d'apprentissage de 0 n'entraînerait aucune adaptation. Le réglage correct du taux d'apprentissage est crucial pour la réussite du processus d'apprentissage. Si la valeur est réglée trop haut, les poids peuvent osciller et compliquer la recherche des valeurs optimales. En revanche, si la valeur est trop faible, les erreurs détectées n'ont pas suffisamment de poids pour pousser le réseau dans une nouvelle optimisation et les poids peuvent se retrouver coincés dans les maximas locaux. Afin de trouver les réglages corrects,
- Le paramètre de dégradation peut être ajouté. Ce paramètre garantit une valeur élevée du taux d'apprentissage dans les premiers cycles du processus de formation pour éviter de se retrouver bloqué dans les maxima locaux et force sa réduction pendant le processus d'apprentissage pour éviter l'oscillation.
- Un autre paramètre important pour les réseaux neuronaux est appelé "momentum". Il est utilisé pour lisser le processus d'optimisation en utilisant une fraction du dernier changement de poids et en l'ajoutant au nouveau changement de poids.
- L'erreur minimale est un critère d'arrêt du processus d'apprentissage.

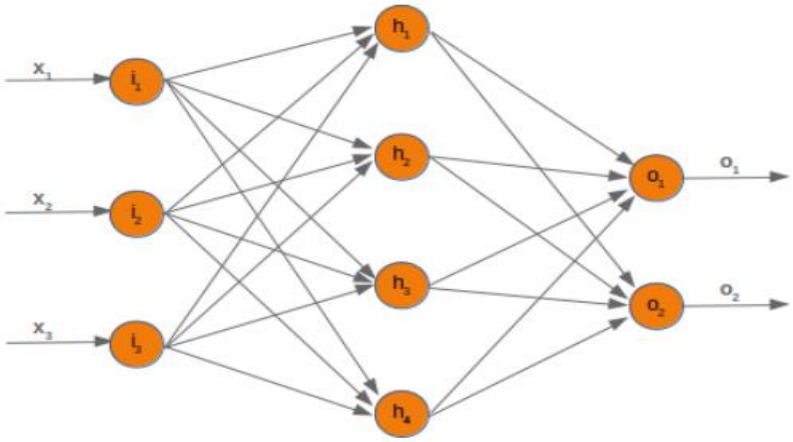

Figure III.3. Exemple d'un réseau de neurone artificiel

III.2.7 Résultats de simulation

Dans cette partie de simulation nous allons mener une étude comparative entre les différents algorithmes les plus utilisés pour la classification des images afin d'identifier celui qui est le mieux adapté pour la classification des lésions cutanées [ABD 19]. Les algorithmes utilisés ici sont ; Régression logistique, Arbre de décision, SVM et KNN. Les arbres de décision, SVM et KNN sont utilisés sous différentes formes :

- Noyaux linéaires, quadratiques et gaussiens pour le SVM.
- Fines, moyennes, cubiques distances pondérées pour le KNN

- Modèles simples, moyens et complexes pour les arbres de décision.

L'évaluation et la validation des modèles de classification sont effectuées sur la base Ph2 qui est fournie en un seul dossier. Ainsi, nous l'avons répartie automatiquement et aléatoirement en une base pour l'apprentissage contenant 80% de la base et une base pour la validation contenant 20% de la base. Tout le processus de l'apprentissage automatique a été respecté à savoir ; la segmentation, l'extraction de caractéristiques, la sélection de caractéristiques et la classification. Les caractéristiques utilisées sont celles sélectionnées et validées par l'algorithme Relief dans le chapitre précédant à savoir : Taille du squelette, Rapport entre la largeur et la longueur du squelette, Nombre de branche, Variance et couleur marron clair.

Le tableau III.1 et la figure III.3 présentes les valeurs de sensibilité, spécificité et exactitude pour les 4 algorithmes de classification. Pour les algorithmes de classification AD, SVM et KNN nous avons utilisé aussi différentes formes du noyau. La sensibilité mesure la classification des Vrai Positif qui nous donne une idée du pourcentage du taux de classification des mélanomes. Le SVM avec un noyau quadratique est le meilleur car il a classé correctement 95,79% des mélanomes de l'ensemble des données. La spécificité mesure la classification des Vrai Négatif qui nous donne une idée du pourcentage du taux de classification des non-mélanomes. Le KNN avec une distance cubique, avec 91,90 % de spécificité, est le meilleur classificateur de non-mélanome. L'exactitude mesure le taux de classification du mélanome et du non-mélanome. Avec 96.50%, le SVM à noyau quadratique est le meilleur entre les 10 classificateurs étudiés.

Tableau III.1. *Sensitivité, Spécificité et exactitude utilisant les 4 algorithmes de classification*

		Sensibilité	*Spécificité*	*Exactitude*
RL		*83.00*	*72.00*	*82.00*
AD	*Simple*	*84.00*	*82.50*	*83.33*
	Moyen	*82.00*	*74.00*	*83.00*
	Complexe	*84.00*	*82.00*	*84.00*
SVM	*Linéaire*	*80.00*	*89.20*	*85.50*
	Quadratique	*90.00*	*92.00*	*91.33*
	Gaussien	*80.00*	*89.20*	*85.50*
KNN	*Fine*	*82.00*	*74.00*	*83.00*
	Moyen	*82.00*	*74.00*	*83.00*
	Cubique	*74.00*	*94.00*	*87.33*

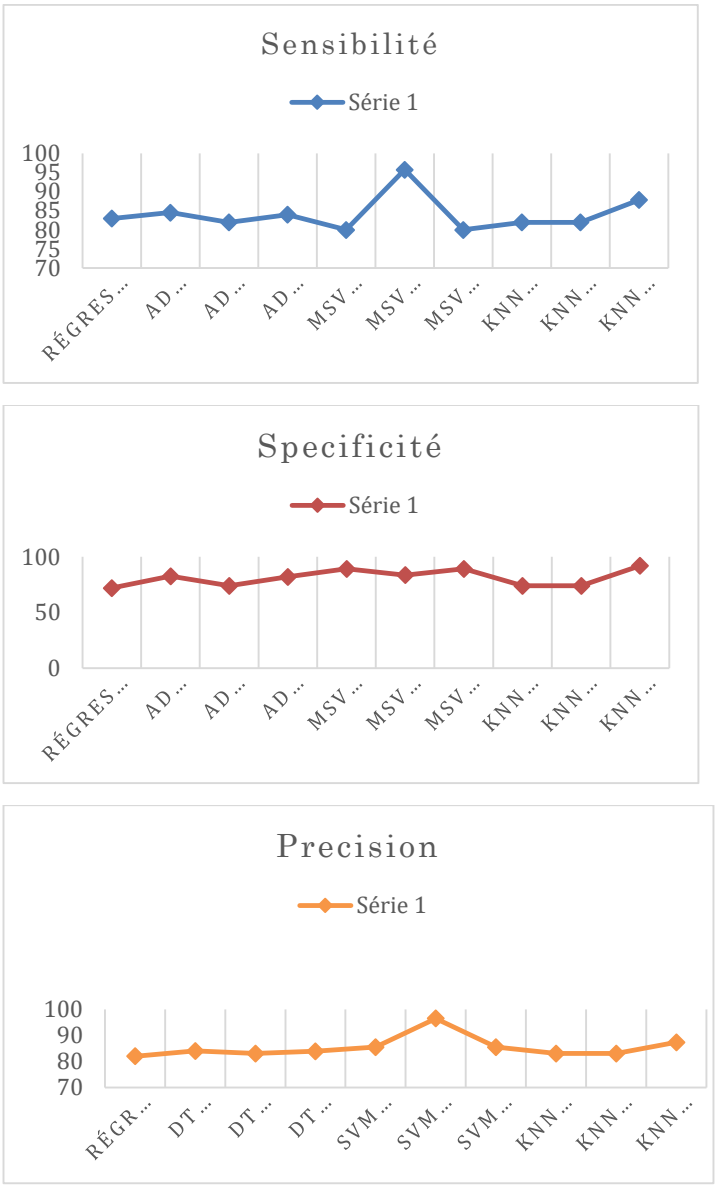

Figure III.4. Comparaison des 4 différents algorithmes de classification

La sensibilité et la spécificité mesurent le pourcentage des taux de TP (Vrai Positif) et de TN (Vrai Négatif). Pour avoir un taux de classification détaillé, le tableau III.2 présente la matrice de confusion qui indique, pour chacun des classificateurs, le nombre de mélanomes correctement classés comme mélanomes, de mélanomes mal classés comme non mélanomes, de non mélanomes mal classés comme mélanomes et de non mélanomes correctement classés comme non mélanomes. Le SVM à noyau quadratique est le meilleur avec seulement 5 lésions mal classées sur 150, suivi du KNN à distance cubique avec 19 lésions mal classées sur 150 et enfin des arbres de décision complexe avec 24 lésions mal classées sur 150.

Tableau III.2. *Matrice de Confusion des meilleurs classificateurs*

		Mélanome	*Non-Mélanome*
SVM Quadratique	*Melanome*	*45*	*8*
	Non-melanome	*5*	*92*
KNN Cubique	*Melanome*	*37*	*6*
	Non-melanome	*13*	*94*
Arbre de décision complexe	*Melanome*	*42*	*17*
	Non-melanome	*8*	*83*

Au terme de cette étude, nous pouvons clairement conclure que le classificateur SVM avec un noyau quadratique reste le meilleur dans la classification des lésions cutanées ; les performances sont bien meilleures lorsqu'on utilise un prétraitement multi-échelle.

III.3 Apprentissage ensembliste adopté pour la classification des lésions cutanées

L'apprentissage ensembliste est une technique bien connue qui permet de combiner plusieurs modèles classification en un seul ensemble classificateur. Un apprentissage ensembliste est construit en générant des bases multiples classificateurs sur des données d'entrainement et en combinant ensuite les prédictions séparées. L'objectif de l'apprentissage ensembliste est de développer un modèle capable de fournir des prévisions plus précises que chacune de ses composantes individuelles. L'apprentissage ensembliste a prouvé qu'il surpasse la capacité de généralisation des classificateurs individuels, il existe trois principales raisons pour lesquelles les ensembles peuvent améliorer la exactitude de leur composante classificateur[LI 14][SCH 13].

Problème statistique : L'objectif des algorithmes de classification est d'apprendre des données afin de trouver le meilleur classificateur (f). Toutefois, il peut être difficile de trouver (f) en utilisant un seul classificateur lorsque la quantité de données d'entrainement disponibles est insuffisante. Lorsque cette situation est produite, le problème d'avoir un petit ensemble de formation peut être résolu en construisant un ensemble de multiples classificateurs. En votant pour l'hypothèse finale, l'ensemble peut donner une approximation satisfaisante de la meilleure solution f.

Problème de calcul : Plusieurs algorithmes effectuent une recherche locale comme la descente de gradient pour rechercher la solution optimale. -Même s'il y a suffisamment de données d'entraînement disponibles (de sorte que le problème statistique ne se pose pas), il est possible que ces algorithmes convergent vers un optimum local. Puisque les techniques pour atteindre l'optimum global peuvent être très gourmandes en calculs, l'apprentissage d'ensemble effectue plusieurs algorithmes de recherche locale qui utilisent les points de

départ de différent dans l'espace de recherche. En utilisant les points de départ de différent, l'ensemble peut se rapprocher de la solution optimale mieux qu'un seul classificateur.

Problème de représentation : Il peut arriver que le classificateur f optimal n'existe pas dans tout l'espace de recherche qui est défini par un simple classificateur. Dans une telle situation, une combinaison de ces classificateurs pourrait donner une approximation plus précise de f que la composante classificateurs prise séparément.

Bien que ces problèmes montrent que l'apprentissage ensembliste peut être plus performant que l'apprentissage individuel des classificateurs dans de nombreuses situations, l'apprentissage ensembliste nécessite la présence d'une diversité suffisante de classificateur pour assurer de bonnes performances.

Le but est de combiner différents algorithmes de classification qui font le moins d'erreurs possible, mais ils doivent faire différentes erreurs pour pouvoir apprendre les uns des autres. La diversité des classificateurs examine un espace plus grand qu'un ou plusieurs classificateur identiques. Lorsque des modèles presque identiques votent pour une prédiction, ils sont tous d'accord et se comportent comme un seul classificateur.

Il existe plusieurs méthodes pour rendre classificateurs les plus diversifiés. Le vote, le bagging et le boosting sont les trois techniques les plus utilisées.

III.3.1 Le vote

Le vote permet à plusieurs classificateurs après un apprentissage indépendamment les uns des autres de voter sur la classe prédite d'une nouvelle entrée par chacun des algorithmes.

Dans un système de vote, on procède à l'apprentissage utilisant différent algorithme et les utiliser ensemble pour prédire la classe d'une nouvelle entrée. On distingue deux types de vote : le vote Majoritaire (Hard voting) et le vote pondéré (Soft Voting).

Le vote dur (Hard voting) consiste à choisir un modèle dans un ensemble pour faire la prédiction finale par un vote à la majorité simple pour la précision. Différentes fonctions de combinaison sont nécessaires à cet égard telles que Moyenne, Max et Majorité

Le vote doux (Soft voting) ne peut être effectué que lorsque tous vos classificateurs peuvent calculer les probabilités des résultats. Le vote indirect permet d'obtenir le meilleur résultat en faisant la moyenne des probabilités calculées par les différents algorithmes.

III.3.2 Boosting

Parmi la famille des méthodes d'ensemble, il existe l'algorithme le plus populaire nommé Boosting qui a été introduit en 1996 par FREUND et SCHAPIRE. Son principe est de convertir les apprenants faibles en apprenants forts, en rassemblant une collection d'apprenants de

faible et moyenne qualité et produire un apprenant d'ensemble qui peut bien fonctionner arbitrairement.

Le principal algorithme de Boosting est AdaBoost qui a été proposé comme une amélioration de l'algorithme original (Boosting 1990). Bien qu'il ait connu plusieurs changements depuis son développement, l'algorithme principal (Boosting) est toujours l'un des plus couramment utilisés. Sa procédure est très simple et repose sur la division de l'ensemble d'entraînement en trois. Le premier tiers est consacré pour entraîner le classificateur et ensuite le tester par le deuxième tiers. Dans ce test, toutes les données mal classées sont utilisées pour former un nouvel ensemble de données et les données de taille égale sélectionnées au hasard sont correctement classées. Ce nouvel ensemble de données est utilisé pour entraîner un deuxième classificateur, puis les deux classificateurs sont testés sur le dernier tiers de l'ensemble de données. Le point de données est ignoré lorsque ces deux classificateurs produisent la même sortie, sinon il est ajouté à un autre nouvel ensemble de données qui présente l'ensemble d'apprentissage du troisième classificateur.

III.3.3 Bagging

Le Bagging a été développée dans un premiers temps par Leo BREIMAN en 1996 [BRE 96], cette méthode se base sur deux principaux étapes ; le bootstrap et l'agrégation. C'est la méthode la plus simple pour combiner les classificateurs.

Pour générer différents apprenants de base [CLA 18], Bagging adopte la distribution bootstrap en appliquant en d'autres termes l'échantillonnage bootstrap. Un échantillon bootstrap est celui qui est tiré de l'ensemble de données d'origine avec remplacement, afin de nous permettre d'obtenir les sous-ensembles de données pour la formation des apprenants de base. En répétant le processus plusieurs fois, on obtient plusieurs échantillons d'apprentissage et à partir de chaque échantillon, un apprenant de base est formé en utilisant l'algorithme d'apprentissage de base.

Pour agréger les résultats des apprenants de base, Bagging adopte une stratégie populaire qui est le vote pour la classification. Cette procédure consiste à alimenter l'instance à ses classificateurs de base tout en collectant toutes leurs sorties, de voter par ensuite les étiquettes et prendre l'étiquette gagnante comme prédiction, où les liens sont rompus arbitrairement.

En résumé, Le bagging utilise des ensembles d'entrainement différent pour chaque composante classificatrice en parallèle, tandis que le boosting forme plusieurs classificateurs en séquence sur des ensembles de formation en utilisant des observations pondérées différentes. Les deux dernières techniques peuvent être utilisées pour résoudre le biais, la variance. Le problème est de minimiser simultanément deux types d'erreur qui limitent les modèles supervisés à généraliser au-delà des données d'entraînement.

Nous pouvons analyser l'erreur attendue d'une observation inaperçue x en termes suivants:

- Biais : une erreur causée par des limitations dans la méthode d'apprentissage.
- Variance : une erreur causée par des limitations dans les données relatives à l'entrainement.

Le bagging et le boosting visent tous deux à minimiser l'erreur estimée, mais ils se concentrent sur les problèmes déferrement.

III.3.4 Résultats de simulation

Pour l'évaluation de l'apprentissage ensembliste, nous allons procéder à un système de vote Majoritaire dur (Max Hard Voting). L' apprentissage est effectué sur la base de données Ph2 à l'aide des algorithmes de classification : SVM avec un noyau quadratique, KNN avec un noyau cubique et AD simple. Le choix de ces algorithmes est basé sur l'étude menée dans la première partie et qui montre qu'ils sont les plus performants pour la classification des lésions cutanées. Et pour la validation, le vote majoritaire est retenu pour décider de la classe de sortie. Les caractéristiques utilisées sont les 5 caractéristiques obtenues après sélection des caractéristiques par l'algorithme Relief.

Dans une première étude, nous comparons les résultats de classifications obtenus pour SVM, KNN et AD avec l'algorithme AdaBoost l'un des plus couramment utilisés de la famille de Boosting.

Tableau III.3. *Sensitivité, Spécificité et Exactitude des différents algorithmes de classification*

	AD complexe	*SVM quadratique*	*KNN cubique*	*AdaBoost*
Sensibilité	*84.00*	*90.00*	*74.00*	*93*
Spécificité	*83.00*	*92.00*	*94.00*	*63*
Exactitude	*84.00*	*91.33*	*87.33*	*93*

Le tableau III.3 présente les résultats de classification utilisant les 3 algorithmes classification et l'algorithme AdaBoost. Bien que Adaboost soit un algorithme de l'apprentissage ensembliste il reste moins performant que le SVM.

Sur le tableau III.4 nous présentons le résultat de classification utilisant le vote majoritaire ainsi que le résultat de classification pour chaque classificateur indépendamment.

Tableau III.4. *Sensitivité, Spécificité et Exactitude utilisant les 4 algorithmes de classification ainsi que le vote majoritaire*

	Apprentissage automatique			*Apprentissage ensembliste*	
	AD complexe	*SVM quadratique*	*KNN cubique*	*AdaBoost*	*Vote Majoritaire*
Sensibilité	*84.00*	*90.00*	*74.00*	*93*	*98*
Spécificité	*83.00*	*92.00*	*94.00*	*63*	*90*
Exactitude	*84.00*	*91.33*	*87.33*	*93*	*97*

Il est clair d'après les résultats présentés dans le tableau III.4 que le vote majoritaire à améliorer le taux de classification et surtout pour les cas des vrais positifs (Sensibilité) ce qui montre que les erreurs de classifications des mélanomes en non-mélanomes sont réduits significativement.

Pour situer notre approche proposée vis-à-vis des approches de la littérature, le tableau III.5 présente le résultat de classification utilisant notre approche de vote en comparaison avec les approches proposées par [BAR 13] et [BI 16] ;

Tableau III.5. *Résultats de classification de notre approche en comparaison avec deux approches de la littérature.*

	Bar et al.	*Bi et al.*	*Vote Majoritaire*
Sensibilité	*85*	*87*	*98*
Spécificité	*87*	*93*	*90*
Exactitude	*87*	*92*	*97*

On remarque bien d'après les résultats de comparaison présentés sur le tableau III .5 que notre approche dépasse de loin les deux approches.

III.4 Conclusion

Cette étude a porté sur l'utilisation des techniques d'apprentissage automatique dans la classification des images des lésions cutanées. La première étude vise à identifier parmi les algorithmes de la classification des images les plus utilisés (Régression logistique, Arbre de décision, SVM et KNN et leur variante) le mieux adapté pour la classification des lésions cutanées. Les résultats des simulations effectuées sur la base Ph2 avec les caractéristiques(Taille du squelette, Rapport entre la largeur et la longueur du squelette, Nombre de branche, Variance et couleur marron clair) validées par l'algorithme de sélection Relief montrent d'une part que SVM avec un noyau quadratique, KNN avec un noyau cubique et Arbre de décision simple sont les plus performants et que Le SVM avec un noyau quadratique reste le meilleur d'autre part et les performances sont encore meilleures lorsqu'on utilise un prétraitement multi-échelle.

La deuxième étude a été consacrée à la classification ensembliste (Ensemble Learning) où il s'agit de combiner les différents algorithmes pour une classification plus efficace. L'étude relative à une comparaison des résultats de classifications obtenus pour SVM, KNN et AD indépendamment est les algorithmes assembliste AdaBoost de la famille de Boosting et le vote majoritaire (Max Hard Voting) prouvent que AdaBoost est moins performant que le SVM. Alors que le vote majoritaire permet d' améliorer le taux de classification et plus particulièrement la Sensibilité et de réduire ainsi significativement les erreurs de classifications des mélanomes en non-mélanomes et qu'il est plus performant que ceux proposés dans la littérature.

Chapitre IV :
Classification des lésions cutanées basée sur l'apprentissage profond

IV.1. Introduction

L'association du traitement d'image et de l'apprentissage automatique (Machine Learning) et/ou de l'apprentissage profond (Deep Learning) a prouvé son efficacité en imagerie médicale et a permis le développement de systèmes robustes pour l'aide au diagnostic de plusieurs maladies.

Dans les précédents chapitres, de nouvelles améliorations ont été présentées au niveaux de la segmentation et l'extraction/sélection de caractéristiques faisant partie des étapes de l'apprentissage automatique. Elles s'appuient sur une décomposition des images des lésions cutanées en deux composantes : « objet » et « texture » et sur de nouvelles caractéristiques relatives au squelette de l'image de la lésion. Cela a contribué d'avoir une segmentation plus précise et un taux de classification automatique très satisfaisant.

Ce chapitre traite de l'utilisation des techniques d'apprentissage profond dans la détection et de la classification des images des lésions cutanées où il s'agit d'extraire d'une manière automatique les caractéristiques à partir d'une image donnée utilisant un réseau de neurones constitué de plusieurs couches. Dans la première partie, nous proposons une amélioration de la classification des lésions cutanées à l'aide d'un réseau neuronal convolutif (Convolutional Neural Network, CNN) dont l'entrée est l'image « texture » issue de la décomposition, puis l'image du squelette des lésions au lieu des images entières. Dans la deuxième partie, nous proposons une approche de classification des lésions cutanées basée sur une fusion de caractéristiques manuelle (Handcrafted features) et des caractéristiques extraites des architectures Deep Learning.

IV.2. Les architectures d'apprentissage profond

IV.2.1. CNN

Cette structure de réseau a été proposée pour la première fois par Fukushima en 1980 [FUK80]. Elle n'a pas pu être utilisée en raison des limites du matériel de calcul pour l'entrainement du réseau. Dans les années 1990, CUN [CUN 90] ont appliqué un algorithme d'apprentissage basé sur les gradients, aux CNNs et ont obtenu des résultats satisfaisants pour le problème de la classification des chiffres manuscrits. Par la suite, les chercheurs ont encore amélioré les CNNs et ont fait de nombreux progrès dans de nombreuses tâches de reconnaissance. Les CNNs présentent plusieurs avantages notamment le fait qu'ils ressemblent davantage au système de traitement visuel humain, que leur structure est hautement optimisée pour le

traitement des images 2D et 3D, et qu'ils sont efficaces pour l'apprentissage et l'extraction des caractéristiques 2D. La couche pooling maximale (max-pooling) des CNNs est efficace pour absorber les variations de forme. De plus, les CNNs ont beaucoup moins de paramètres qu'un réseau entièrement connecté de taille similaire.

De plus, les CNNs sont entraînés via l'algorithme d'apprentissage basé sur le gradient et souffrent moins du problème de diminution du gradient. Étant donné que l'algorithme basé sur le gradient entraîne l'ensemble du réseau à minimiser directement un critère d'erreur, les CNN peuvent produire des poids hautement optimisés.

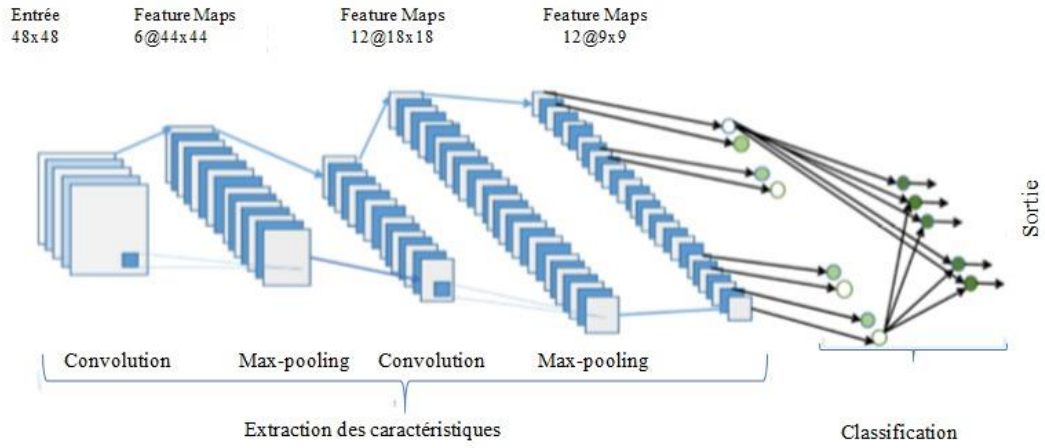

Figure IV.1. Architecture générale du CNN

La figure IV .1 montre que l'architecture globale des CNN se compose de deux parties principales: L'extraction de caractéristiques et un classificateur. Dans les couches d'extraction de caractéristiques, chaque couche du réseau reçoit en entrée la sortie de sa couche immédiatement précédente et transmet sa sortie en entrée à la couche suivante. L'architecture du réseau CNN est constituée d'une combinaison de trois types de couches : la convolution, le max-pooling et la classification. Il existe deux types de couches dans les niveaux inférieur et intermédiaire du réseau : Les couches de convolution et les couches de max pooling. Les couches paires sont destinées aux convolutions et les couches impaires aux opérations de pooling. Les nœuds de sortie des couches de convolution et de max-pooling sont regroupés dans un plan 2D appelé "feature mapping". Chaque plan d'une couche est généralement dérivé de la combinaison d'un ou plusieurs plans de couches précédentes. Les nœuds d'un plan sont connectés à une petite région de chaque plan connecté de la couche précédente. Chaque nœud de la couche de convolution extrait les caractéristiques des images d'entrée par des opérations de convolution sur les nœuds d'entrée.

Les caractéristiques de niveau supérieur sont dérivées des caractéristiques propagées à partir des couches de niveau inférieur. Lorsque les caractéristiques se

propagent vers la couche ou le niveau le plus élevé, les dimensions des caractéristiques sont réduites en fonction de la taille du noyau pour les opérations de convolution et du max-pooling respectivement. Cependant, le nombre de carte ou « map » d'éléments a généralement augmenté pour représenter de meilleures caractéristiques des images d'entrée afin d'assurer la exactitude de la classification. La sortie de la dernière couche du CNN est utilisée comme entrée d'un réseau entièrement connecté qui est appelé couche de classification. Les feed-forward réseaux de neurone ont été utilisés comme couche de classification car ils sont plus performants [HIN 10]. Dans la couche de classification, les caractéristiques extraites sont prises comme entrées par rapport à la dimension de la matrice de poids du réseau neuronal final. Cependant, les couches entièrement connectées sont coûteuses en termes de réseau ou de paramètres d'apprentissage.

Les détails sur les différentes couches de CNN sont abordés dans la section suivante.

IV.2.1.1. Couche convolutionnelle

Dans cette couche, les cartes de caractéristiques (features maps*)* des couches précédentes sont convoluées avec des noyaux. La sortie des noyaux passe par une fonction d'activation linéaire ou non linéaire, comme les fonctions sigmoïde, tangente hyperbolique, Softmax, linéaire ect, pour former les cartes de caractéristiques de sortie. Chacune des cartes de caractéristiques de sortie peut être combinée avec plus d'une carte de caractéristiques d'entrée.

IV.2.1.2. Couche de sous-échantillonnage « Sub-sampling Layer »

La couche de sous-échantillonnage effectue l'opération de sous-échantillonnage sur les cartes d'entrée. C'est ce qu'on appelle communément la couche du pooling. Dans cette couche, le nombre de cartes des caractéristiques d'entrée et de sortie ne change pas. En raison de l'opération de sous-échantillonnage, la taille de chaque dimension des cartes de sortie sera réduite, en fonction de la taille du masque de sous-échantillonnage.

IV.2.1.3. Couche de classification

C'est la couche entièrement connectée qui calcule le score de chaque classe à partir des caractéristiques extraites d'une couche convolutive dans les étapes précédentes. Les cartes de caractéristiques (features map) de la couche finale sont représentées sous forme de vecteurs, avec des valeurs scalaires qui sont transmises aux couches entièrement connectées. Les couches neuronales de feed-forward entièrement

connectées sont utilisées comme couche de classification soft-max. Il n'y a pas de règles strictes sur le nombre de couches qui sont incorporées dans le modèle de réseau. Cependant, dans la plupart des cas, deux à quatre couches ont été observées dans différentes architectures, notamment LeNet [LEC 05], AlexNet [KRI 07] et VGG Net [SIM 15]. Comme les couches entièrement connectées sont coûteuses en termes de calcul, des approches alternatives ont été proposées ces dernières années. Il s'agit notamment de la couche moyenne pooling qui vise à réduire considérablement le nombre de paramètres dans le réseau. Lors de la retro-propagation à travers les CNNs, la couche entièrement connectée se met à jour selon l'approche générale des réseaux neuronaux entièrement connectés (FCNN). Dans ce sens, les filtres des couches convolutionnelles sont mis à jour en effectuant l'opération convolutionnelle complète sur les cartes de caractéristiques entre la couche convolutionnelle et sa couche immédiatement précédente.

Dans cette section, plusieurs architectures de CNN seront dévisagées [ALO 19]. En général, la plupart des réseaux neuronaux convolutionnels profonds sont constitués d'un ensemble de couches de base, dont : couche de convolution, couche de sous-échantillonnage, couches denses et la couche soft-max. Les architectures sont généralement constituées de plusieurs couches convolutionnelles et de couches max-pooling, suivies d'une couche entièrement connectée et d'une couche SoftMax à la fin.

Quelques exemples de ces modèles sont LeNet [LEC 05], AlexNet [KRI 07], VGG Net [SIM 15], NiN [LIN 14] et tous les modèles convolutionnels (All Conv) [ALO 19][SPR 15]. D'autres alternatives et des architectures avancées plus efficaces ont été proposées, notamment DenseNet [HUA 17], FractalNet [LAR 19], GoogLeNet avec des unités I*nception* [SZE 14] et des réseaux résiduels. Les éléments de base de la construction (convolution) qui sont presque les mêmes dans toutes ces architectures. Cependant, certaines différences topologiques sont observées dans les architectures modernes d'apprentissage profond. Parmi les nombreuses architectures du CNNs : AlexNet [KRI 07], VGG Net [SIM 15], GoogLeNet [SZE 14], Dense CNN [HUA 17] et FractalNet [LAR 19] sont généralement considérées comme les architectures les plus populaires en raison de leurs performances pour les tâches de reconnaissance d'objets et de classification. Parmi toutes ces structures, certaines sont spécialement conçues pour l'analyse de données à grande échelle (comme GoogLeNet et ResNet), tandis que le réseau VGG est considéré comme une architecture générale. Certaines des architectures sont denses en termes de connectivité, comme DenseNet.

IV.2.2. LeNet

Bien que LeNet ait été proposé dans les années 1990, les capacités de calcul et la limitation de la mémoire limitées ont rendu l'algorithme difficile à mettre en œuvre

jusqu'au environ de 2010 [LEC 05]. LECUN et ses collaborateurs ont toutefois proposé des CNNs avec l'algorithme de rétro-propagation et ont expérimenté sur des ensembles de données numériques écrite à la main pour obtenir une précision et de la comparé avec les anciennes méthodes. L'architecture CNN proposée est connue sous le nom de LeNet5. La configuration de base de LeNet-5 est la suivante (voir figure IV.2) : Deux couches de convolution (conv), deux couches de sous-échantillonnage (sub-sampling layers), deux couches entièrement connectées, et une couche de sortie avec la connexion gaussienne. Alors que les capacités du matériel informatique commençaient à s'améliorer, les CNNs ont déclaré qu'elles devenaient populaires en tant qu'approche efficace pour apprentissage dans les domaines de la vision par ordinateur et de l'apprentissage machine[ALO 19].

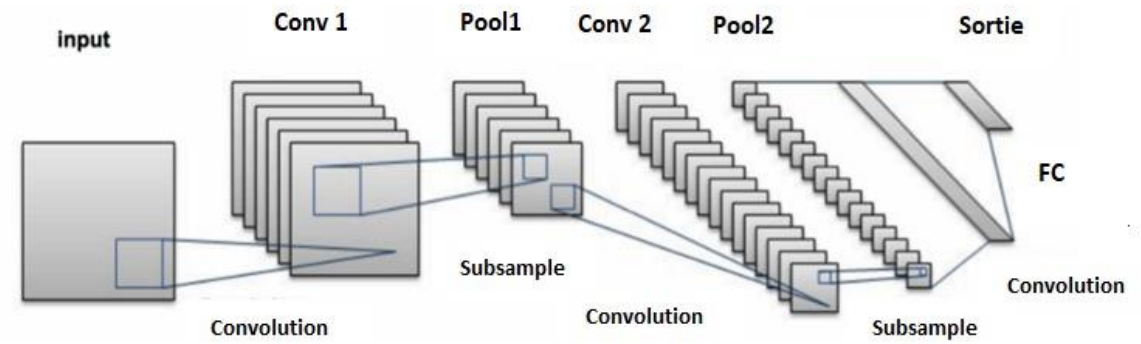

Figure IV.2. Architecture de LeNet [LEC 05]

IV.2.3. AlexNet

En 2012, Alex Krizhevesky et d'autres ont proposé un modèle CNN plus profond et plus large que LeNet et ont remporté le défi le plus difficile d'ImageNet pour la reconnaissance d'objets visuels, appelé ImageNet Large Scale Visual Recognition Challenge (ILSVRC) en 2012 [KRI 07] [ALO 19]. AlexNet a atteint une haute précision de reconnaissance par rapport à toutes les approches traditionnelles d'apprentissage machine et de vision par ordinateur. Ce fut une percée significative dans le domaine de l'apprentissage machine et de la vision par ordinateur pour les tâches de reconnaissance visuelle et de classification et c'est le point de l'histoire où l'intérêt pour l'apprentissage approfondi a rapidement augmenté.

L'architecture d'AlexNet est illustrée à la figure IV .3. La première couche convolutive effectue la convolution et le max-pooling avec la normalisation de la réponse locale, où 96 filtres réceptifs de différents taille 11 × 11 sont utilisés. Les opérations max-pooling sont effectuées avec des filtres de taille 3 × 3 et de pas de 2. Les mêmes opérations sont effectuées dans la deuxième couche avec un filtre de 5 ×

5. Les filtres 3 × 3 sont utilisés dans les troisième, quatrième et cinquième couches convolutionnelles avec respectivement 384, 384 et 296 cartes de caractéristiques. Deux couches entièrement connectées (FC) sont utilisées avec un d*ropout* suivi d'une couche Softmax à la fin. Deux réseaux ayant une structure similaire et le même nombre de cartes de caractéristiques sont formés en parallèle pour ce modèle. Deux nouveaux concepts, la normalisation de la réponse locale (NRL) et dropout, sont introduits dans ce réseau.

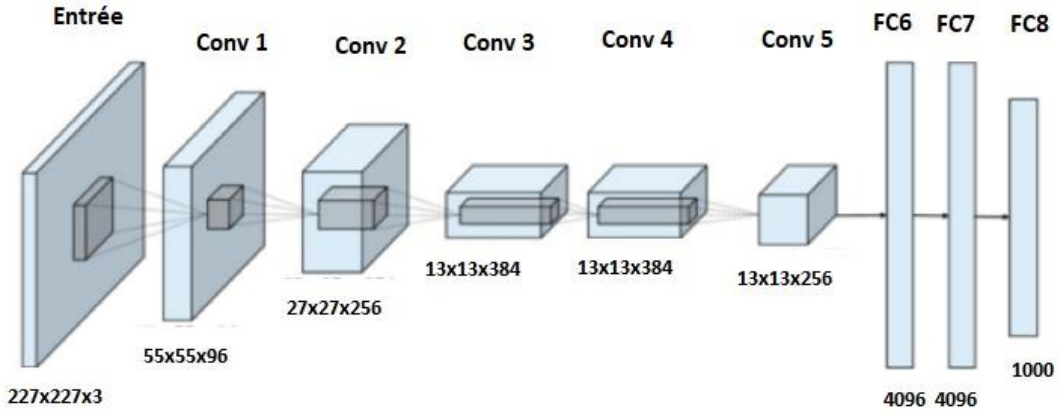

Figure IV.3. Architecture d'Alexnet [KRI 07]

IV.2.4. ZFNet / Clarifai

En 2013, Matthew Zeiler et Rob Fergue ont remporté l'ILSVRC 2013 avec une architecture CNN qui était une extension d'AlexNet. Le réseau a été appelé ZFNet [ZEI 14], du nom des auteurs. Les CNN étant coûteux en termes de calcul, une utilisation optimale des paramètres est nécessaire du point de vue de la complexité du modèle. L'architecture ZFNet est une amélioration d'AlexNet, conçue en ajustant les paramètres du réseau de ce dernier[ALO 19]. ZFNet utilise des noyaux 7x7 au lieu de 11x11 pour réduire considérablement le nombre de poids. Cela permet de réduire considérablement le nombre de paramètres réseau et d'améliorer la précision globale de la reconnaissance.

IV.2.5. Network in network (NiN)

Ce modèle est légèrement différent des modèles précédents où quelques nouveaux concepts sont introduits [LIN 14]. Le premier concept consiste à utiliser la convolution de perception multicouche, où les convolutions sont effectuées avec un filtre 1×1 qui aide à ajouter plus de non-linéarité dans les modèles. Cela permet d'augmenter la profondeur du réseau, qui peut ensuite être régularisé avec le dropout. Le deuxième concept consiste à utiliser Global Average Pooling (GAP) comme alternative aux

couches entièrement connectées. Cela permet de réduire considérablement le nombre de paramètres du réseau [ALO 19]. Le GAP modifie la structure du réseau de manière significative. En appliquant le GAP sur une grande carte de caractéristiques, nous pouvons générer un vecteur de caractéristiques final de faible dimension sans réduire la dimension des cartes de caractéristiques.

IV.2.6. VggNet

Le Visual Geometry Group (VGG), a été le second de l'ILSVRC 2014. La principale contribution de ce travail est qu'il montre que la profondeur d'un réseau est un élément essentiel pour obtenir une meilleure reconnaissance ou une meilleure précision de classification dans les CNNs [ALO 19]. L'architecture VGG se compose de deux couches convolutionnelles qui utilisent toutes deux la fonction d'activation ReLU. La fonction d'activation est suivie d'une seule couche du max-pooling et de plusieurs couches entièrement connectées utilisant également une fonction d'activation ReLU. La dernière couche du modèle est une couche Softmax pour la classification. Trois modèles VGG-11, VGG-16 et VGG-19, ont été proposés, les modèles ayant respectivement 11, 16 et 19 couches. Le modèle de réseau VGG est illustré à la figure VI. 4.



Figure IV.4. Architecture du VggNet [SIM 15]

Toutes les versions des modèles VGG-E se terminaient de la même façon avec trois couches entièrement connectées. Cependant, le nombre de couches de convolution variait : le VGG-11 contenait 8 couches de convolution, le VGG-16 en avait 13 et le VGG-19 en avait 16.

IV.2.7. GoogLeNet

GoogLeNet, le gagnant de l'ILSVRC 2014 [SZE 14] [ALO 19], était un modèle proposé par Christian Szegedy de Google dans le but de réduire la complexité des calculs par rapport au CNN traditionnelle. La méthode proposée consistait à

incorporer des couches *Inception* comportant des champs réceptifs variables, créés par des noyaux de tailles différentes. Ces champs réceptifs ont créé des opérations qui ont permis de capturer des modèles de corrélation dispersés dans des cartes de caractéristiques.

Le concept initial de la couche d'inception est illustré à la figure VI. 5. GoogLeNet a amélioré la précision de la reconnaissance en utilisant une pile de couches initiales, comme le montre la figure VI.5. La différence entre la couche de départ naïve et la couche de départ finale était l'ajout de noyaux de convolution 1x1. Ces noyaux ont permis de réduire les dimensions avant les couches coûteuses en termes de calcul. GoogLeNet était composé de 22 couches au total, ce qui était bien plus important que n'importe quel réseau avant lui. Une version améliorée qui cependant, le nombre de paramètres de réseau utilisés par GoogLeNet était beaucoup plus faible que celui de son prédécesseur AlexNet ou VGG. GoogLeNet avait 7M de paramètres réseau alors qu'AlexNet en avait 60M et VGG-19 138M.

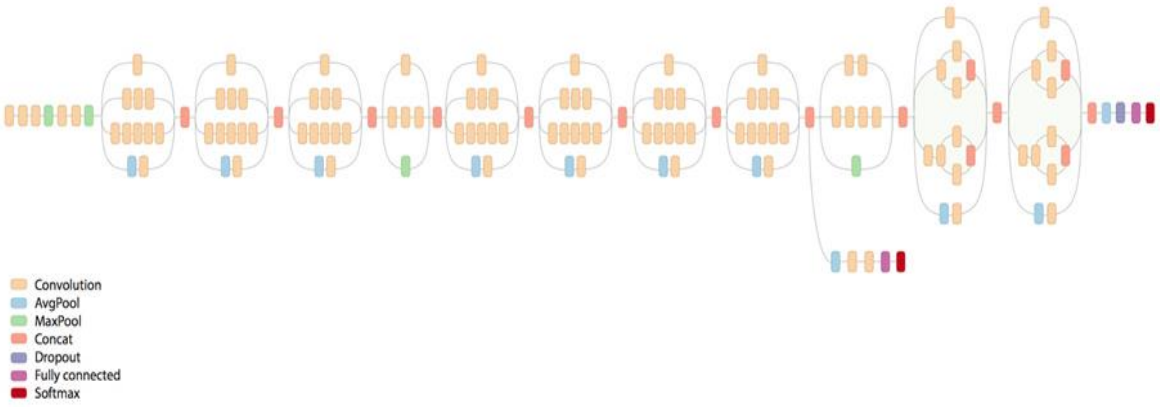

Figure IV.5. Architecture du GoogleNet [SZE 14]

IV.2.8. Réseau des résidus (ResNet)

Le gagnant de l'ILSVRC 2015 a été l'architecture de réseau résiduelle, ResNet [He 16]. ResNet a été développé par Kaiming He avec l'intention de concevoir des réseaux ultra-profonds qui ne souffrent pas du problème du **vanishment gradient** que connaissaient les précédents. ResNet est développé avec un grand nombre de couches différentes : 34, 50, 101, 152, et même 1202. Le populaire ResNet50 contenait 49 couches de convolution et une couche entièrement connectée à la fin du réseau. Le nombre total de poids de l'ensemble du réseau est de 25,5 M figure VI .6.

Le réseau résiduel est constitué de plusieurs blocs résiduels de base. Cependant, les opérations dans le bloc résiduel peuvent varier en fonction des différentes architectures des réseaux résiduels. La version élargie du réseau résiduel a été

proposée par [ZAG 16][ALO 19], une autre approche améliorée du réseau résiduel connue sous le nom de transformation résiduelle agrégée.

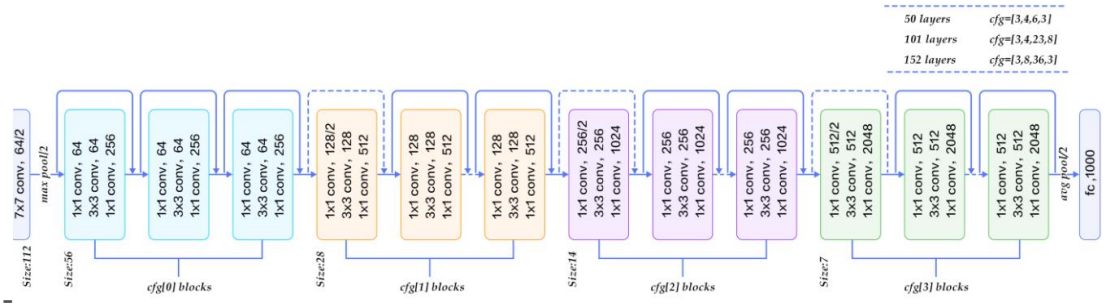

Figure IV.6. Architecture du Resnet [He 16]

IV.2.9. Densely Connected Network (DenseNet)

DenseNet développé par Gao en 2017[HUA 17][ALO 19], qui se compose de couches CNN connectées de manière dense, les sorties de chaque couche sont connectées à toutes les couches suivantes dans un bloc dense. Par conséquent, il est formé avec une connectivité dense entre les couches, ce qui lui vaut le nom de DenseNet. Ce concept est efficace pour la réutilisation des caractéristiques, ce qui réduit considérablement les paramètres du réseau. Le DenseNet est constitué de plusieurs blocs denses et de blocs de transition, qui sont placés entre deux blocs denses adjacents.

IV.3. Apprentissage profond basé sur la texture et du squelette des lésions cutanées

Dans cette partie, nous proposons une amélioration de la détection et de la classification des lésions cutanées à l'aide d'un réseau neuronal convolutif (Convolutional Neural Network, CNN) dont l'entrée est l'image « texture » issue de la décomposition, puis l'image du squelette des lésions au lieu des images entières.

IV.3.1. Apprentissage profond basé sur des composantes multi-échelles

Dans cette approche, une méthode d'apprentissage profond utilisant une décomposition multi-échelles est présentée pour aider à la classification des lésions cutanées pigmentées et de fournir une méthode pour aider les dermatologues dans leurs diagnostics. Figure. IV. 7 illustre cette approche, et les trois étapes sont expliquées ci-dessous[FIL 19c] :

- Prétraitement de l'image: L'image d'entrée est décomposée séparément en composants de texture et d'objet par une décomposition multi-échelle.
- Segmentation de l'image: Tout d'abord, la segmentation est effectuée sur la composante objet. Ensuite, la texture et la segmentation sont projetées ensemble pour créer la lésion texturée.
- Dans le réseau neuronal convolutionnel, l'extraction et la classification des caractéristiques sont effectuées séparément sur les composantes texture et objet.

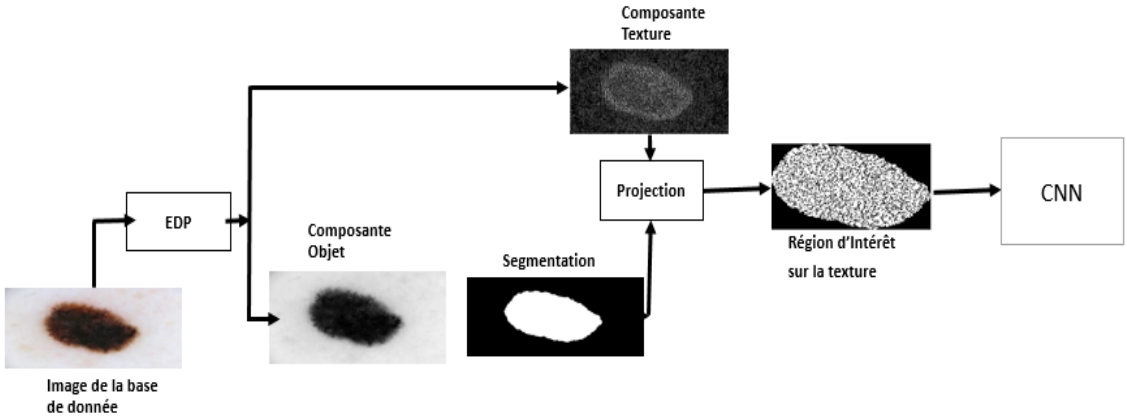

Figure IV.7. Approche proposée pour l'entrainement des images de dermotalogie en utilisant la texture comme entrée au CNN

Dans cette partie, les CNNs utilisés consistent en deux couches convolutives avec un noyau 3*3. Il y a 32 cartes de caractéristiques dans la première et la deuxième couche de convolution. Une fonction non linéaire est généralement appliquée à la sortie de la convolution, dans notre approche nous utilisons la fonction Relu. Ensuite, une couche de max pooling est appliquée après chaque couche de convolution avec un noyau 2*2. Les sorties de ces quatre couches sont aplaties en de 2 couches entièrement connectées ayant respectivement 128 neurones. Les deux dernières couches utilisent une fonction d'activation Softmax pour transformer la sortie en probabilités afin de classifier le cancer de peau. La classe ayant la plus grande probabilité est ensuite choisie. L'approche proposée est illustrée sur la Figure IV.8 .

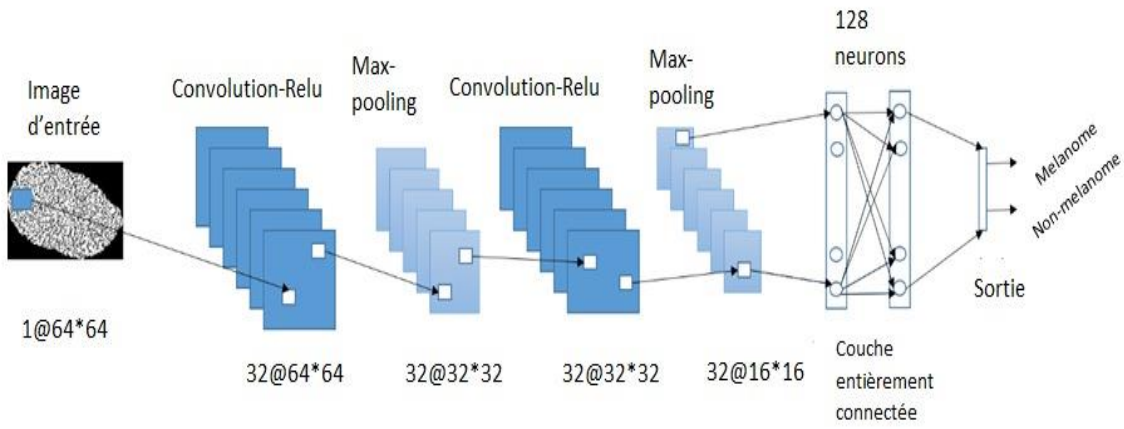

Figure IV.8. Architecture de l'apprentissage profond adoptée

IV.3.2. Apprentissage profond basé sur le squelette des lésions

Les squelettes des lésions sont une représentation efficace permettant de décrire correctement la forme et la taille des lésions et donc de les classer efficacement comme mélanome ou non-mélanome. Par conséquent, l'idée proposée dans cette partie est d'utiliser le squelette des lésions comme entrée du CNN au lieu des images originales. L'expérimentation montre que cette idée peut à la fois augmenter le taux de classification, par rapport aux approches récentes de la littérature, et donc réduire le nombre de couches utilisées pour créer le réseau profond.

L'extraction de caractéristiques efficaces de la lésion cutanée est un défi plus important que tous les travaux des chercheurs pour aider les dermatologues à établir un bon diagnostic. Dans nos travaux précédents, nous avons utilisé la forme du squelette pour décrire la lésion, ce qui a prouvé l'efficacité de la classification du cancer de la peau. Nous avons remarqué que le squelette du cancer du mélanome est différent, plus grand et plus développé que le squelette du non-mélanome. De ces lésions du squelette, les caractéristiques extraites étaient le nombre de points terminaux, c'est-à-dire un pixel actif qui a exactement un pixel voisin actif, le nombre de branches, où deux branches ou plus se rencontrent, le nombre de sous-branches, la taille du squelette, la longueur et la largeur de l'image du squelette, le rapport entre la largeur et la longueur du squelette, et la longueur maximale et minimale entre deux points terminaux. Le problème qui se pose à partir de ces lésions du squelette, est de savoir comment extraire toutes les caractéristiques qui peuvent bien représenter la lésion. Pour cela, le réseau neural convolutif (CNN) sera utilisé pour extraire toutes les caractéristiques du squelette et améliorer encore le taux de précision.

Dans cette approche, un réseau neural convolutif extraira les caractéristiques effectives du squelette de la lésion. La squelettisation peut préserver l'information de la lésion, décrire la forme de la lésion et conserver la propriété des formes de la lésion. Le squelette sera l'entrée d'un réseau neural convolutif (CNN) pour extraire les caractéristiques et classer la lésion cutanée en mélanome ou non mélanome.

La figure IV.9 présente le schéma de l'approche proposée.

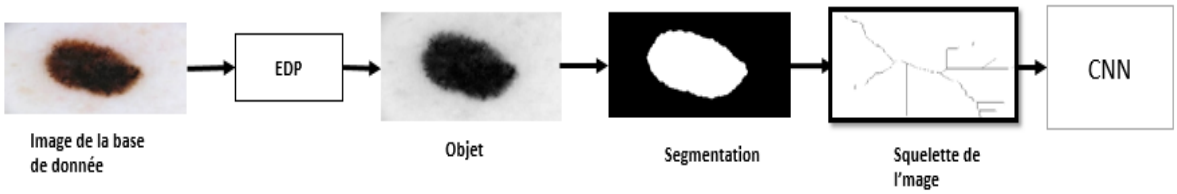

Figure IV.9. Approche proposée basée sur le squelette

IV.3.3. Résultats de simulation

Le prétraitement est la première étape de l'approche que nous proposons, qui consiste à éliminer le bruit et les artefacts de la lésion. Comme vu dans le chapitre 2, chaque image est divisée en deux composantes distinctes : la composante texture et la composante objet. La décomposition est faite par le modèle Aujol. Grâce à cette décomposition, la composante objet permettra une meilleure reconnaissance du contour de l'objet et peut donner un moyen simple de segmenter la lésion et d'obtenir une bonne région d'intérêt. La lésion segmentée est obtenue par segmentation de la composante objet utilisant l'algorithme Otsu. Par la suite le squelette de la lésion sera obtenu par squelettisation du masque de segmentation. Ces 3 composantes (Objet, texture et squelette) seront utilisées séparément comme entrée du réseau neural convolutif (CNN).

Les tests sont effectués utilisant la base du challenge ISIC qui une base de grande taille en comparaison avec les deux autres bases utilisées dans cette thèse. Le choix de cette base-est justifié par le fait que l'apprentissage profond donne de meilleur résultat que l'apprentissage automatique.

Le tableau IV. 1 présente les résultats de classification des images de la base ISIC utilisant respectivement les composantes objets, textures, régions d'intérêt sur partie texture, et squelettes. Les résultats obtenus seront comparés à ceux obtenus par classification automatique utilisant les caractéristiques obtenues manuellement (Handcrafted features). Ces caractéristiques sont celles obtenues après sélection par la méthode Relief. La classification est effectuée utilisant l'algorithme de classification SVM.

Tableau IV. 1. Résultat de l'apprentisage profond utilisant les composantes objets, textures, régions d'intèrêt et squelettes.

Méthode	*Apprentissage automatique*	*Deep CNN*			
		Composantes « Objet »	*Composantes « Texture »*	*Régions d'intérêt*	*Squelettes*
Exactitude	*82.00%*	*86.21%*	*93.50%*	*89.50%*	*95.00%*

D'après les résultats présentés sur le tableau IV. 1 on peut constater que :

- L'apprentissage profond permet une meilleure exactitude de classification que l'apprentissage automatique.
- L'utilisation des composantes objets issues de la décomposition par EDP conduit à la plus faible valeur de la précision de classification soit un taux de classification égale à 86.21%,
- L'utilisation de seulement la lésion (région d'intérêt) comme entrée du réseau CNN contribue à une légère amélioration du taux de classification. Par contre l'utilisation la texture de la lésion permet une nette amélioration du taux de classification. En effet, la texture comporte un nombre important d'informations permettant de différencier entre une lésion mélanome et non-mélanome,
- Comme pour le cas de l'apprentissage automatique, les caractéristiques issues du squelette de la lésion sont pertinentes et leur utilisation en tant qu'entrée du réseau CNN conduit à la meilleure précision de classification (95.00%).

Dans cette étude seule l'architecture CNN d'apprentissage profond a été utilisée puisqu'elle est plus facile à mettre en œuvre. D'autres architectures ont prouvé leur efficacité dans la classification des images, à savoir AlexNet et Vgg16. Ainsi, nous avons cherché à déterminer la meilleure architecture, parmi AlexNet, Vgg16 et CNN, à utiliser pour la classification des lésions cutanées.

Dans la série d'expérimentation effectuée, La configuration des architectures est la suivante :

- AlexNet contient huit couches. Cinq couches de convolution, dont certaines sont mises en flux par un max-pooling et à la fin 3 couches entièrement connectées.
- Vgg16 contient 13 couches de convolution et 3 couches entièrement connectées.
- CNN contient 2 couches de convolution et 2 Max-pooling

- Les entrées des architectures sont respectivement les images brutes de la base de données et les images du squelette des lésions obtenues par la segmentation suivie de la squelettisation de la composante « objet ».

Tableau IV. 2. Résultat en terme de temps d'exécution de l'approche proposée

Entrée	*Images initiales*			*Squelettes*		
Architectures DL	*AlexNet*	*Vgg16*	*CNN*	*AlexNet*	*Vgg16*	*CNN*
Précision (%)	*89.50*	*94.50*	*83.18*	*81.00*	*80.02*	*95.00*
Temps (minutes)	*68,27*	*79,32*	*55,18*	*43.49*	*50.20*	*40,37*

Le tableau IV .2 présente les résultats de classification obtenus en termes de précision et du temps d'exécution nécessaire à l'entrainement. La différence dans le temps d'exécution entre les différentes implémentations est justifiée par la taille de l'architecture et aussi pas le type d'image en entrée. En effet, les images brutes de la base de données ISIC sont des images couleurs RGB alors que les images du squelette sont binaires. On peut constater que pour le cas des où les entrées des architectures sont les images initiales le VGG16 reste le meilleur ce qui a été déjà démontré par d'autres travaux. Par contre dans le cas de l'utilisation les images des squelettes des lésions comme entrées des architectures, le taux de précision obtenu par l'architecture CNN est nettement améliorée et a dépassé le VGG16. On peut conclure que la squelettisation avec CNN aboutit à une très bonne précision de classification.

Bien que ce taux de classification soit satisfaisant, il reste loin de 100% désiré. Pour cette raison, nous proposons une nouvelle approche de la classification des lésions cutanées qui associe la puissance de l'apprentissage automatique et l'apprentissage profond.

IV.4. Fusion de l'apprentissage profond et extraction manuelle des caractéristiques

Les performances de l'apprentissage machine (ML) et de l'apprentissage profond (DL) sont étroitement liées à la taille de l'ensemble des données d'apprentissage. Ainsi, avec de grands ensembles de données, les approches basées sur l'apprentissage automatique sont moins puissantes que celles basées sur l'apprentissage profond et vice versa.

Face aux limites des approches ML et DL vis à vis de la dimension des bases d'images, nous proposons dans cette section une approche de classification des lésions cutanées basée sur une fusion de caractéristiques manuelle (Handcrafted

features) et des caractéristiques extraites des architectures DL. La démarche suivie dans cette approche comprend les phases suivantes (figure IV. 10).

1- Extraction manuelle des caractéristiques (Handcrafted features) à partir de la forme, le squelette, la texture et la couleur

2- Extraction des caractéristiques par application des architectures de l'apprentissage profond.

3- Sélection de caractéristiques

4- Classification par l'algorithme SVM

L'approche proposée sera par la suite validée et testée à la fois sur des bases d'images de petite et de grande taille. Une étude comparative est également menée pour comparer l'approche proposée avec différentes et récentes approches appliquées à chaque ensemble de données.

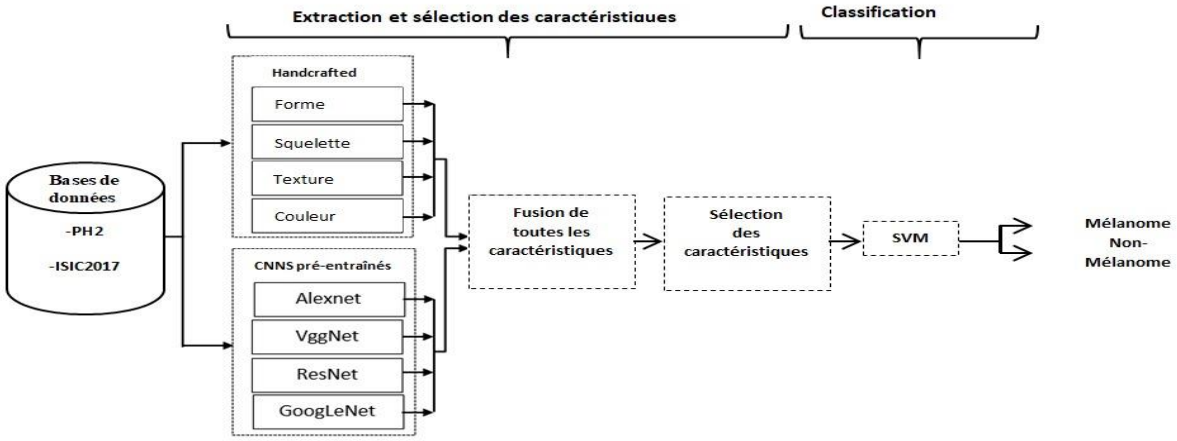

Figure IV.10. Approche proposée de fusion de ML et DL pour la classification des lésions cutanées

IV.4.1. Extraction des caractéristiques

L'extraction de caractéristiques est composée de deux parties : des caractéristiques manuelles et des caractéristiques CNN préformées.

- **Caractéristiques manuelles**

Les caractéristiques extraites dites manuelle (handcratftred) sont la forme, le squelette, la texture et la couleur de la lésion. Un prétraitement des images des lésions de la peau est effectué pour éliminer l'artefact, améliorer la qualité de la segmentation ainsi que des caractéristiques extraites. Une décomposition multi-échelle utilisant le modèle d'Aujol est utilisé comme vu dans le chapitre II.

La projection de la région d'intérêt de l'image segmentée sur la composante de texture sera utilisée pour extraire les caractéristiques de texture.

La projection de l'image segmentée sur l'image originale sera utilisée pour diagnostiquer la différence entre les deux types comme l'utilisent les dermatologues dans le cadre d'un diagnostic normal.

Un total de 34 caractéristiques extraites des caractéristiques manuelles.

- Caractéristiques de la forme : Le plus grand diamètre, le plus petit diamètre, le périmètre, la surface, l'excentricité, l'excentration, le diamètre équivalent et la circularité. (8)
- Caractéristiques du squelette : Nombre de points terminaux, nombre de points de branche, nombre de sous-branches, la taille du squelette, la longueur et la largeur de la lésion du squelette, le rapport entre la largeur et la longueur du squelette, la longueur minimale et maximale entre deux points terminaux, (9)
- Caractéristiques de la texture : Le contraste, l'énergie, la corrélation, l'homogénéité, la dérivation standard, l'entropie, la douceur, la différence inverse moment, l'aplatissement, la moyenne quadratique, l'asymétrie, (11)
- Caractéristiques des couleurs : Ces couleurs sont le blanc, le rouge, le marron clair, le marron foncé, le bleu-gris et le noir, (6)

- **Caractéristiques pré-formées**

Le réseau neural convolutif (CNN) peut être utilisé de deux manières différentes, la première consiste à utiliser les données avec une formation pour apprendre à partir des données, et la seconde consiste à utiliser le CNN avec un transfert d'apprentissage. Dans ce travail, nous optons pour le second type d'utilisation de manière que les caractéristiques sont extraites à partir de quatre architectures différentes de réseau préformé : (AlexNet, VggNet, GoogLeNet et ResNet).

Les caractéristiques sont extraites des dernières couches entièrement connectées (FC) des réseaux AlexNet et Vgg16 préformés. Pour ResNet18 et GoogLeNet, puisqu'il ne possède qu'une seule couche FC, les caractéristiques sont extraites de la dernière couche convolutionnelle de ces modèles pré-entrainés. 1000 caractéristiques sont extraites de chaque CNN, soit un total de 4000 caractéristiques.

Une première expérimentation, est réalisée pour étudier le comportement de l'algorithme de classification en fonction des caractéristiques extraites manuelles ou CNN pre-entrainnées considérées séparément. Le Tableau IV.3 présente le résultat de l'exactitude, précision, et F mesure obtenu pour les deux bases d'images Ph2 et ISIC séparément.

Tableau IV. 3. Résultat de classification pour les differentes caractertistiques

	Caractéristiques manuelles	*AlexNet*	*GoogLeNet*	*Vgg16*	*Resnet18*
Exactitude (accuracy) % (PH2)	*90.5*	*87*	*87.5*	*87*	*88*
F-mesure % (PH2)	*93.43*	*91.98*	*92.36*	*91.90*	*92.82*
Précision% (PH2)	*96*	*93*	*96*	*95*	*97*
Exactitude (accuracy) % (ISIC)	*80.3*	*80.7*	*82*	*81.6*	*81.5*
F-mesure % (ISIC)	*30.44*	*40.48*	*31.42*	*27.83*	*29.75*
Précision% (ISIC)	*45*	*48*	*55*	*52*	*51*

IV.4.2. Sélection de caractéristiques

La sélection des caractéristiques est une étape primordiale et peut améliorer nettement le taux de classification en ne gardant que les caractéristiques les plus pertinentes. Pour cette raison, nous allons procéder à une sélection des caractéristiques issues de chacune des implémentation (caractéristiques manuelles et celles extraites des 4 architectures DL) utilisant cette fois les algorithmes génétiques (GA). Cette étape sera effectuée pour les deux bases de données Ph2 et ISIC. Le tableau IV.4 présente le résultat de sélection des caractéristiques.

La sélection des caractéristiques a permis de réduire significativement le nombre de caractéristiques à utiliser pour les deux bases de données. Pour la base de données PH2, les caractéristiques sélectionnées sont au nombre de 406 dont 10 caractéristiques manuelles et 396 caractéristiques provenant de CNN. Pour la base de données ISIC ,160 caractéristiques sont sélectionnées qui contiennent 7 caractéristiques manuelles et 153 caractéristiques de CNN préformées.

Tableau IV. 4. Sélection des caractéristiques en utilisant le génétique algorithme

	Caractéristiques Initiales	Caractéristiques Sélectionnées	
		Ph2	ISIC
Forme	8	3	1
Squelette	9	3	3
Texture	11	2	1
Couleur	6	2	2
AlexNet	1000	109	7
VggNet	1000	100	29
GoogleNet	1000	98	45
ResNet	1000	89	72
Total	4034	406	160

IV.4.3. Fusion des caractéristiques

Ces caractéristiques sélectionnées seront fusionnées et utilisées par l'algorithme de classification SVM pour la conception de notre modèle. Le tableau IV.5 présente les valeurs de sensibilité, spécificité et précision, F-mesure kappa et l'exactitude pour chaque base de données.

Tableau IV. 5: Résultat de la classification en utilisant la sélection des caractéristiques sur les deux bases d'images Ph2 et ISIC

	Sensibilité (%)	Spécificité (%)	Précision (%)	F-mesure (%)	Kappa (%)	Exactitude (%)
PH2	92.5	99	97	94.69	93.63	98
ISIC	55	95	73	62.73	55.68	87.8

D'après les résultats présentés sur le tableau IV.5 on peut constater que l'exactitude de classification est élevée et ce pour les deux bases d'images. Pour la base ISIC qui est une base de challenge un taux de classification égal à 87.8 est un très bon taux. Sachant que la matrice de confusion nous permet de voir de près des erreurs de classification et surtout des mélanomes en des non-mélanomes. Les résultats présentés sur le tableau IV.6 montrent clairement que notre approche proposée a réduit significativement le nombre de faux positifs pour les deux bases. Une seule image mélanome est mal classée en non-mélanome pour la base PH2.

Tableau IV. 6. La matrice de confusion de notre modèle de classification pour les deux bases d'images Ph2 et ISIC

	PH2		*ISIC*	
	Mélanome	*Non-mélanome*	*Mélanome*	*Non mélanome*
Mélanome	*37*	*1*	*206*	*76*
Non-mélanome	*3*	*159*	*168*	*1550*

Le tableau IV.7 présente la exactitude de la classification de la base d'images PH2 en utilisant l'approche que nous proposons, en comparaison avec les approches récentes proposées respectivement par J. A. Salido [SAL 18b], N. Moura [MOU 18], S. Pathan [PAT 19] , M. Nasir [NAS 18], Tallha Akram [AKR 18]. Dans J. A. Salido utilise AlexNet comme architecture DL pour l'extraction de caractéristiques et a obtenu un taux d'exactitude de 93,00 %. D'autre part, N. Moura classe les lésions cutanées à l'aide d'un descripteur hybride obtenu en combinant des caractéristiques de couleur, de forme, de texture et de réseaux neuronaux convolutifs préformés. Ces caractéristiques sont utilisées comme entrées d'un classificateur Perceptron multicouche et ont obtenu un taux d'exactitude de 96,5 %. Dans S. Pathan, utilise une architecture d'ensembliste robuste, qui est développée en utilisant des techniques de sélection dynamique de classificateur pour classer les lésions cutanées et a obtenu un taux d'exactitude de 97%. Muhammad Nasir utilise une série de méthodes qui sont appliquées par la suite et qui permettent également d'extraire et de fusionner des caractéristiques telles que la couleur, la texture et la forme (HOG). Les caractéristiques fusionnées sont ensuite sélectionnées en appliquant une nouvelle méthode d'entropie de Boltzman. Enfin, les caractéristiques sélectionnées sont classées par SVM et obtiennent un taux de précision égal à 97,5 %. Akram de Tallha utilise des critères d'extraction de caractéristiques et de réduction de la dimension, qui combinent des techniques d'extraction de caractéristiques conventionnelles et récentes et obtiennent une précision de classification de 97,5 %.

Tableau IV. 7. Résultats de l'approche proposée en comparaison avec des approches récentes de la littérature pour la base d'images PH2 [FIL 20b]

	Salido [SAL 18b]	*Moura [MOU 18]*	*Pathan [PAT 19]*	*Nasir [NAS 18]*	*Akram [AKR 18]*	*Approche proposée*
Année	*2018*	*2018*	*2019*	*2018*	*2018*	*2020*
Précision (%)	*93.00*	*96.5*	*97.00*	*97.5*	*97.5*	*98.00*

Le tableau IV.8 présente la précision de la classification utilisant la base d'images ISIC de notre approche proposée en comparaison avec des approches récentes

proposées respectivement par Iván González-Díaz [GON 17] , Kazuhisa Matsunaga [MAT 17] , Amirreza Mahbod [MAH 19], Lei Bi [LEI 17] . Iván González-Díaz a utilisé un savoir d'expert incorporé des dermatologues dans les réseaux neuronaux convolutionnels (CNN) et a obtenu un score de 82,3% de taux de classification. D'autre part, Kazuhisa Matsunaga a utilisé un modèle préformé pour classer les mélanomes par réseau neuronal profond et a obtenu un taux de précision de 82,8 %. Amirreza Mahbod a proposé une méthode automatique pour la classification des lésions cutanées, qui utilise les caractéristiques profondes des réseaux de neurones profonds. Ils utilisent trois modèles profonds préformés, à savoir AlexNet, VGG16 et ResNet-18. Les caractéristiques extraites sont utilisées par SVM et ils ont obtenu un taux de précision de 83,83 %. Lei Bi a utilisé une analyse automatique des lésions cutanées en utilisant la nouvelle architecture de Deep Residual Networks Resnet et a obtenu un taux de précision de 85,5 %.

Tableau IV. 8. Résultats de l'approche proposée en comparaison avec des approches récentes de la littérature pour la base d'images ISIC [FIL 20b]

	González-Díaz [GON 17]	*Matsunaga [MAT 17]*	*Mahbod [MAH 19]*	*Bie [LEI 17]*	*Approche proposée*
Année	*2017*	*2017*	*2019*	*2017*	*2020*
Précision (%)	*82.3*	*82.8*	*83.83*	*85.5*	*87.8*

L'approche que nous proposons a obtenu un score plus élevé que les approches récentes de la littérature avec un taux de précision égal à 98% pour l'ensemble de données PH2 et 87,8% pour l'ensemble de données ISIC. Ceci est dû d'une part à la fusion des caractéristiques manuelles et préformées et d'autre part aux algorithmes génétiques en tant que sélection de caractéristiques qui prouve l'efficacité de celles qui ont été sélectionnées comme étant les meilleures et les plus pertinentes.

Bien que l'approche proposée se soit avérée très performante tant pour la Ph2 que pour les ensembles de données de la ISIC, il persiste certaines limites qui peuvent être abordées dans les travaux futurs. Le nombre de méthodes préformées et manuelles que nous avons réalisées est limité. L'extension d'un plus grand nombre de modèles préformés tels que DenseNet et Inception permettra d'améliorer encore les performances de la classification. De plus, l'extension des données de formation devrait permettre d'obtenir de meilleurs résultats pour chaque méthode ainsi que pour leurs combinaisons. La difficulté consiste à trouver les meilleures et les plus pertinentes caractéristiques qui devraient fonctionner pour toutes les bases de données et donner le meilleur score.

IV.5. Conclusion

L'apprentissage machine (ML) et l'apprentissage profond (DL) ont été appliqués avec différentes configurations dans le développement des systèmes d'aide au diagnostic. Dans ce chapitre, nous nous sommes intéressés à la classification des lésions cutanées à base de l'apprentissage profond. Ainsi, nous avons proposé dans un premier temps d'utiliser respectivement les images « objet » , « texture » et « squelette » obtenues par décomposition multi-échelle de l'image dermoscopique de la lésion cutanée comme entrée d'un réseau CNN au lieu des images initiales. Les résultats expérimentaux montrent que l'approche proposée utilisant les squelettes des lésions comme entrée d'une architecture CNN nous a permis d'avoir un taux de classification très satisfaisant.

Les approches de classification basées sur le DL donnent de très bons résultats si elles sont appliquées sur de grandes bases comme ISIC mais sont moins efficaces pour les petites bases comme Ph2. Et inversement, les approches basées sur le ML sont très efficaces sur les petites bases d'images et moins efficaces que le DL pour les grandes bases. Ainsi, nous avons proposé de fusionner les puissances de ML et DL afin de proposer un modèle de classification puissant à la fois sur les grandes et petites bases d'images. Alors, nous avons proposé par la suite de fusionner les caractéristiques manuelle (forme, squelette, couleur et texture) obtenues dans une implémentation ML avec celles obtenues par des architectures DL basées sur les réseaux neuronaux convolutifs (CNN). Les expérimentations ont été validées et testées sur de petites et grandes bases d'images PH2 et ISIC. La fusion de ces nouvelles caractéristiques après sélection par l'AG nous ont contribué à une nette amélioration du taux de classification avec 98% pour la base de données PH2 et 87,8% pour la base de données ISIC 2.

Conclusion Générale et perspectives

L'introduction des systèmes automatiques d'aide au diagnostic médical dans les programmes de prévention du cancer de la peau, devient primordiale, puisqu'il constitue aujourd'hui une cause assez importante , en progression chaque année de mortalité. Il constitue l'outil de prévention primaire pour réduire à terme le taux de mortalité et maximiser les chances de survie. En imagerie médicale, l'aide au diagnostic fait intervenir plusieurs disciplines et domaines notamment le traitement d'image, vision artificielle et reconnaissance des formes et classification et l'intelligence artificielle. Dans ce contexte, nous avons conduit plusieurs études relatives à l'amélioration des résultats de la détection et de la classification des lésions cutanées à travers la proposition d'approches relatives aux fonctions principales d'un système de dépistage du cancer de la peau, aussi bien niveau de la segmentation des image et de la sélection des caractéristiques qu'au niveau de la stratégie de la classification automatique.

Nous avons entamé ce manuscrit par une description du contexte médical, les règles retenues pour le diagnostic clinique. Ensuite, nous avons présenté les systèmes d'aide à au diagnostic, la méthodologie de leur conception ainsi que les étapes nécessaires à leur réalisation afin de justifier le choix des algorithmes utilisés dans l'élaboration de notre système DAO. La seconde partie de ce manuscrit porte sur nos contributions dans la réalisation du système de détection automatique des lésions cutanées qui porte sur les sous-systèmes dépendants les uns des autres, notamment : le prétraitement, la segmentation, l'extraction des caractéristiques, et les algorithmes de classification.

La première contribution a porté sur la segmentation, des images dermoscopiques des lésions cutanées, qui constitue une étape cruciale dans le processus de classification. En effet, une bonne segmentation conduit à une meilleure identification et détection de la lésion. Dans ce contexte, nous avons proposé de procéder à une décomposition multi-échelle par le biais des EDPs. Cette décomposition aboutit à extraire séparément deux composantes de l'image ; la première contient l'information relative aux objets présents dans l'image et la deuxième contient l'information sur la texture et le bruit. La segmentation est effectuée sur la composante objet. Les résultats de simulation ont montré une nette amélioration des performances même pour des algorithmes les plus simple de segmentation des images.

La seconde contribution concerne la caractérisation des lésions cutanées. Le sous-système de caractérisation reçoit en entrée le masque de la lésion obtenu par l'approche de segmentation de la composante objet. Ce masque a été caractérisée en s'appuyant sur la démarche des dermatologues dans le processus de diagnostic et sur les différentes attributs de textures. Ainsi, les caractéristiques de texture sont extraites de la composante texture, les caractéristiques de forme et de couleur sont

extraites à partir du masque de la lésion. La forme de la lésion est le plus important paramètre pris en considération dans le diagnostic du mélanome. Nous avons proposé ainsi de nouvelles caractéristiques de forme basées sur la squelettisation qui renferment des informations pertinentes et complémentaires aux informations usuelles extraites pour décrire la forme de la lésion. Cette caractérisation a été suivi par une réduction de dimensionnalité à travers une étude comparative avec différentes procédures de sélection afin d'obtenir la sélection optimale qui conduit à une augmentation de la précision des prédictions. Les caractéristiques retenues sont au nombre de 5 obtenues par l'algorithme de sélection Relief.

La troisième contribution traite de l'application des approches de l'apprentissage automatique dans la phase ultime du système. Nous avons commencé par une étude comparative entre les différents algorithmes usuels pour la classification des images afin d'identifier celui qui est le mieux adapté pour la classification des lésions cutanées. Les algorithmes considérés sont ; Régression logistique, Arbre de décision, SVM et KNN. Les arbres de décision, SVM et KNN ont été utilisés sous différents noyaux. L'évaluation et la validation des modèles de classification sont effectuées sur la base Ph2. Les résultats des expérimentations ont montré que le SVM à noyau quadratique est le meilleur, suivi du KNN à distance cubique. Une seconde étude a été consacrée à la classification ensembliste (Ensemble Learning) où il s'agit de combiner différents algorithmes pour une classification plus efficace. Nous avons procédé à un apprentissage sur la base de données Ph2 par les algorithmes de classification SVM avec un noyau quadratique, KNN avec un noyau cubique, AD simple. Pour l'évaluation de l'apprentissage ensembliste, un vote dur majoritaire (Max Hard Voting) a été appliqué pour décider de la classe de sortie. Le résultat de classification montre que d'une part que le vote majoritaire améliore nettement le taux et aussi la sensibilité de classification.

Dans un dernier travail, nous nous sommes intéressés à la classification à base de l'apprentissage profond. Ainsi, nous avons proposé dans un premier temps d'utiliser respectivement les images « objet », « texture » et « squelette » obtenues par décomposition multi-échelle de l'image dermoscopique de la lésion cutanée comme entrée d'un réseau CNN au lieu des images initiales. Les résultats expérimentaux montrent que l'approche proposée utilisant les squelettes des lésions comme entrée d'une architecture CNN conduit à un taux de classification très satisfaisant. D'autre part, ils sont moins efficaces sur les petites bases. Ainsi, nous avons proposé par la suite de fusionner les caractéristiques manuelle (forme, squelette, couleur et texture) obtenues dans une implémentation ML avec celles obtenues par des architectures DL basées sur les réseaux neuronaux convolutifs (CNN). Les expérimentations ont été validées et testées sur de petites et grandes bases d'images PH2 et ISIC. La fusion de ces nouvelles caractéristiques après sélection par l'AG ont contribué à une nette

amélioration du taux de classification avec 98% pour la base de données PH2 et 87,8% pour la base de données ISIC 2. Les résultats obtenus sont jugés très encourageants et très probants aussi bien pour les bases d'images de faible dimension que celles de grande dimension. En conclusion, nous considérons que les objectifs tracés pour répondre à la problématique de détection et de classification des lésions cutanées ont été largement atteints.

En revanche, plusieurs solutions peuvent être développées dans de futures travaux. Parmi les perspectives envisagées, nous citons:

- Utilisation d'un Vote pondéré pour la classification ensembliste.
- Implémentation de notre système proposé sur des cartes:
  - Raspberry.
  - FPGA.

Bibliographies

[ABD 19] Abdelouahed, S., Filali, Y. and Ennouni, A. (2019) 'An overview of skin lesion segmentation , features engineering and classification. Intelligent Decision Support Systems Applications in Signal Processing Ed . by Borra , Surekha Series : Frontiers in Computational Intelligence', (November). doi: 10.1515/9783110621105-002.

[ABU 14] Abu Mahmoud, M. K. and Al-Jumaily, A. (2014) 'Novel feature extraction methodology based on histopathalogical images and subsequent classification by support vector machine', 2014 World Symposium on Computer Applications and Research, WSCAR 2014. doi: 10.1109/WSCAR.2014.6916803.

[AGG 14] Aggarwal, C. C. et al. (2014) 'Active learning: A survey', Data Classification: Algorithms and Applications, pp. 571–605. doi: 10.1201/b17320.

[AKR 18] Akram, T. et al. (2018) 'Skin lesion segmentation and recognition using multichannel saliency estimation and M-SVM on selected serially fused features',Journal of Ambient Intelligence and Humanized Computing. Springer Berlin Heidelberg, 0(0), p. 0. doi: 10.1007/s12652-018-1051-5.

[ALO 19] Alom, M. Z. et al. (2019) 'A state-of-the-art survey on deep learning theory and architectures', Electronics (Switzerland), 8(3), pp. 1–67. doi: 10.3390/electronics8030292.

[ANS 17] Ansari, U. B. and Sarode, T. (2017) 'Skin Cancer Detection Using Image Processing', International Research Journal of Engineering and Technology (IRJET) Volume: 04 Issue: 04, pp. 2875–2881.

[ARC 85] Arcplli, C., Sanniti, G. and Baja, D. I. (1985) 'A Width-Independent Fast Thinning Algorithm', IEEE Trans. Patt. Anal. Machine Intell., 7: 463-474. DOI: 10.1109/TPAMI.1985.4767685

[BAR 13] Barata, C., Marques, J. S. and Rozeira, J. (2013) 'Evaluation of color based keypoints and features for the classification of melanomas using the bag-of-features model', Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 8033 LNCS(PART 1), pp. 40–49. doi: 10.1007/978-3-642-41914-0_5.

[BAR 18] Barata, A. C. F., Celebi, E. M. and Marques, J. (2018) 'A Survey of Feature Extraction in Dermoscopy Image Analysis of Skin Cancer', IEEE Journal of Biomedical and Health Informatics. IEEE, PP(8), p. 1. doi: 10.1109/JBHI.2018.2845939.

[BAS 13] Baskin, I., Marcou, G. and Varnek, A. (2013) 'Tutorial on Ensemble Learning', Researchgate.Net, (May), pp. 1–36. Available at: http://www.researchgate.net/publication/236651928_Tutorial_on_Ensemble_Learning/file/3deec518b262443d54.pdf.

[BEI 16] Bi, L. et al. (2016) 'Automatic Melanoma Detection via Multi-scale Lesion-biased Representation and Joint Reverse Classification School of Information Technologies , University of Sydney , Australia Sydney Medical School , University of Sydney , Australia Med-X Research Instit', pp. 1055–1058.

[BEU 17] Beumier, C. and Neyt, X. (2017) 'Camera Motion Compensation from T-junctions in Distance Map Skeleton', Proceedings of the International Conference on Systems, Signals and Image Processing, May 22-24, IEEE Xplore Press, Poznan, Poland, pp: 1-5. DOI: 10.1109/IWSSIP.2017.7965613

[LEI 17] Bi, L. et al. (2017) 'Automatic Skin Lesion Analysis using Large-scale Dermoscopy Images and Deep Residual Networks',arXiv preprint arXiv: 1703.04197 pp. 6–9.

[BRE 96] Breiman, L. (1996) 'Bagging predictions', Machine Learning, 24(2), pp. 123–140.

[CAL 79] Calmettes, A. and Guillaume, C. (1979) 'Vision par ordinateur – Filtre de Gabor', 794, pp. 1–20.

[CEL 07] Celebi, M. E. et al. (2007) 'A methodological approach to the classification of dermoscopy images', Computerized Medical Imaging and Graphics, 31(6), pp. 362–373. doi: 10.1016/j.compmedimag.2007.01.003.

[CHO11]Hassan CHOUAIB Sélection de caractéristiques : méthodes et applications ;Thèse de l'université Paris Descartes Université Paris Descartes UFR de Mathématiques et Informatique ED Informatique, télécommunications et Electronique en juillet 2011.

[CLA 18] Clarke, B. S. and Clarke, J. L. (2018) Ensemble Methods, Predictive Statistics. doi: 10.1017/9781139236003.012.

[COD 17] Codella, N. C. F. et al. (2017) 'Skin Lesion Analysis Toward Melanoma Detection: A Challenge At The 2017 International Symposium On Biomedical Imaging (ISBI)', pp. 1–5.

[COD 18] Codella, N. C. F. et al. (2018) 'Skin lesion analysis toward melanoma detection : a challenge at the 2017 international symposium on biomedical imaging (ISBI), HOSTED BY THE INTERNATIONAL SKIN IMAGING COLLABORATION (ISIC) IBM T . J . Watson Research Center , Yorktown Heights , NY , U', (Isbi), pp. 168–172.

[CUN 90] Cun, y. Le, Boser, B. and Denker, J. . (1990) 'Handwritten digit recognition with a back-propagation network', Chapman Hall/CRC Publishers. p. 368.

[DAL 17] Dalila, F. et al. (2017) 'Segmentation and classification of melanoma and benign skin lesions', Optik. Elsevier GmbH., 140, pp. 749–761. doi: 10.1016/j.ijleo.2017.04.084.

[DAS 97]Dash, M. and Liu, H. (1997) 'Feature selection for classification', Intelligent Data Analysis, 1(3), pp. 131–156. doi: 10.3233/IDA-1997-1302.

[DEM 77]Dempster, A. P., Laird, N. M. and Rubin, D. B. (1977) ' Maximum Likelihood from Incomplete Data Via the EM Algorithm ', Journal of the Royal Statistical Society: Series B (Methodological), 39(1), pp. 1–22. doi: 10.1111/j.2517-6161.1977.tb01600.x.

[DOI 07] Doi, K. (2007) 'Computer-aided diagnosis in medical imaging: historical review, current status and future potential', Computerized medical imaging and graphics. Elsevier, 31(4–5), pp. 198–211.

[DRE 00] Dreiseitl, S., Ohno-Machado, L. and Binder, M. (2000) 'Comparing Three-class Diagnostic Tests by Three-way ROC Analysis', Medical Decision Making, 20(3), pp. 323–331. doi: 10.1177/0272989X0002000309.

[DRE 01] Dreiseitl, S. et al. (2001) 'A comparison of machine learning methods for the diagnosis of pigmented skin lesions.', Journal of biomedical informatics, 34(1), pp. 28–36. doi: 10.1006/jbin.2001.1004.

[DUN 73] Dunn, J. C. (1973) 'A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters', Journal of Cybernetics, 3(3), pp. 32–57. doi: 10.1080/01969727308546046.

[ELG 13] Elgamal, M. (2013)'automatic skin cancer images classification', International Journal of Advanced Computer Science and Applications 4(3).

[FAS 11] Fassihi, N. et al. (2011) 'Melanoma diagnosis by the use of wavelet analysis based on morphological operators', IMECS 2011 - International MultiConference of Engineers and Computer Scientists 2011, pp. 193–196.

[FIL 17a] Filali, Y. and Sabri, M. A. (2017) 'An improved apporach for skin lesion analysis based on multiscale decomposition', 2017 International Conference on Electrical and Information Technologies (ICEIT). ISBN: 978-1-5386-1516-4. DOI: 10.1109/EITech.2017.8255250. 15-18 Nov. 2017. Rabat, Morocco.pp. 1–6.

[FIL 17b] Filali, Y. Sabri, M. A et Aarab, A, (2017);. "Multiscale approach for skin lesion analysis and classification". 2017 International Conference on Advanced Technologies for Signal and Image Processing (ATSIP). ISBN: 978-1-5386-0551-6. DOI: 10.1109/ATSIP.2017.8075545. 22-24 May 2017. Fez, Morocco.

[FIL 18] Filali, Y. et al. (2018) 'A study of lesion skin segmentation, features selection and classification approaches'. International Conference on Intelligent Systems and Computer Vision (ISCV). Pages: 1-4. ISBN: 978-1-5386-4396-9. DOI: 10.1109/ISACV.2018.8354069. 2-4 April 2018. Fez, Morocco.

[FIL 19a] Filali, Y., Sabri, M. A. and Aarab, A. (2019b) 'An improved segmentation approach for skin lesion classification, (May). doi: 10.19139/soic.v7i2.533.

[FIL 19b] Filali, Y. et al. (2019) 'New and Efficient Features for Skin Lesion Classification based on Skeletonization'. Journal of Computer Science. DOI: 10.3844/jcssp.2019.1225.1236. Septembre 2019, Volume 15, Issue 9. pp 1225.1236.

[FIL 19c] Filali, Y. et al. (2019) 'Texture Classification of skin lesion using convolutional neural network', 2019 International Conference on Wireless Technologies, Embedded and Intelligent Systems (WITS). IEEE, pp. 5–6. doi: 10.12792/iiae2017.004.

[FIL 20a] Filali, Y., Sabri, M. A. and Aarab, A. (2020) 'Improving Skin Cancer Classification Based on Features Fusion and Selection',

Advances in Intelligent Systems and Computing, 1076, pp. 379–387. doi: 10.1007/978-981-15-0947-6_36.

[FIL 20b] Filali, Y. et al. (2020) 'Efficient fusion of handcrafted and pre-trained CNNs features to classify melanoma skin cancer', Multimedia Tools and Applications. Multimedia Tools and Applications, 79(41–42), pp. 31219–31238. doi: 10.1007/s11042-020-09637-4.

[FRE 13] Frezza-Buet, H. (2013) 'Machines à Vecteurs Supports : Didacticiel', Supélec (Support de cours), pp. 1–43. Available at: http://www.metz.supelec.fr/metz/personnel/frezza/ApprentissageNumerique/svm-fr-ereader.pdf.

[FRI 85] Friedman, R. J., Rigel, D. S. and Kopf, A. W. (1985) 'Early Detection of Malignant Melanoma: The Role of Physician Examination and Self-Examination of the Skin', CA: A Cancer Journal for Clinicians, 35(3), pp. 130–151. doi: 10.3322/canjclin.35.3.130.

[FUK 80] Fukushima, K. (1980) 'Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position',
Biological Cybernetics, 36(4), pp. 193–202. doi: 10.1007/BF00344251.

[GAR 11] Garnavi, R. et al. (2011) *'Automatic segmentation of dermoscopy images using histogram* thresholding on optimal color channels', World Academy of Science, Engineering and Technology, 55(May 2014), pp. 1040–1048. doi: 10.5281/zenodo.1058449.

[GIL 06] Gilles, J. (2006) *'Décomposition et détéction de structures géométriques en imagerie',*pp.1–168.Available GIlles-Décomposition et détéction de structures géométriques en imagerie.

[GON 17] González-Díaz, I. (2017) *'DermaKNet: Incorporating the Knowledge of Dermatologists to Convolutional Neural Networks for Skin Lesion Diagnosis',* IEEE Journal of Biomedical and Health Informatics, 23(2), pp. 547–559. doi: 10.1109/JBHI.2018.2806962.

[GUP 17] Gupta, A., Issac, A. and Dutta, M. K. (2017) *'Adaptive Thresholding For Skin Lesion Segmentation Using Statistical Parameters',* pp. 616–620. doi: 10.1109/WAINA.2017.36.

[GUY 08] GUYON, I. and BARNHILL, J. W. S. (2008) *'Gene Selection for Cancer Classification using Support Vector Machines',* Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 5139 LNAI, pp. 62–72. doi: 10.1007/978-3-540-88192-6-8.

[HAL 73] Haralick, R. M., Shanmugam, K. and Dinstein, I. (1973) *'Textural Features for Image Classification'.*

[HAL 99] Hall, M. A. (1999) 'Correlation-based Feature Selection for Machine Learning', (April).

[HE 16] He, K. et al. (2016) *'Identity mappings in deep residual networks',* Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 9908 LNCS, pp. 630–645. doi: 10.1007/978-3-319-46493-0_38.

[HIN 10] Hinton, G. E., Osindero, S. and Teh, Y.-W. (2010) *'A Fast Learning Algorithm for Deep Belief Nets',* International Journal of Environmental Science and Development, 1554, pp. 341–346. doi: 10.7763/ijesd.2010.v1.67.

[HSS 14] HSSINA, B. et al. (2014) *'A comparative study of decision tree ID3 and C4.5',* International Journal of Advanced Computer Science and Applications, 4(2). doi: 10.14569/specialissue.2014.040203.

[HUA 11] Huang, J., Wu, D. and Li, C. (2011) 'Development of Electrical Impedance Spectroscopy and Tomography System', 16, pp. 135–140.

[HUA 17] Huang, G. et al. (2017) *'Densely connected convolutional networks',* Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, 2017–Janua, pp. 2261–2269. doi: 10.1109/CVPR.2017.243.

[IMM 15] Immagulate, I. and Vijaya, M. S. (2015) 'Categorization of Non Melanoma Skin Lesion Diseases Using Support Vector Machine and Its Variants', 3(2), pp. 34–40. doi: 10.11648/j.ijmi.20150302.15.

[INZ 04] Inza, I. et al. (2004) *'Filter versus wrapper gene selection approaches in DNA microarray domains.',* Artificial intelligence in medicine. Netherlands, 31(2), pp. 91–103. doi: 10.1016/j.artmed.2004.01.007.

[JAL 12] Jaleel, J. A., Salim, S. and Aswin, R. B. (2012) *'Artificial Neural Network Based Detection of Skin Cancer',* International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering, 1(3), pp. 200–205.

[JAL 13] Jaleel, J. A., Salim, S. and Aswin, R. B. (2013) *'Computer aided detection of skin cancer',* Proceedings of IEEE International Conference on Circuit, Power and Computing Technologies, ICCPCT 2013, pp. 1137–1142. doi: 10.1109/ICCPCT.2013.6528879.

[KAN 18] Kannan, V. (2018) *'Feature Selection using Genetic Algorithms'* Master's Projects. 618. DOI: https://doi.org/10.31979/etd.6mq4-cp5p.

[KAS 88] Kass, M., Witkin, A. and Terzopoulos, D. (1988) *'Snakes: Active contour models',* International Journal of Computer Vision, 1(4), pp. 321–331. doi: 10.1007/BF00133570.

[KHA 19a] Khan, M. Q. et al. (2019) *'Classification of Melanoma and Nevus in Digital Images for Diagnosis of Skin Cancer',* IEEE Access. IEEE, PP, p. 1. doi: 10.1109/ACCESS.2019.2926837.

[KHA 19b] Khairunnahar, L. et al. (2019) 'Classification of malignant and benign tissue with logistic regression', Informatics in Medicine Unlocked. Elsevier Ltd, 16(May), p. 100189. doi: 10.1016/j.imu.2019.100189.

[KIR 92] Kira, K. and Rendell, L. A. (1992) *A Practical Approach to Feature Selection,* Machine Learning Proceedings 1992. Morgan Kaufmann Publishers, Inc. doi: 10.1016/b978-1-55860-247-2.50037-1.

[KNI 00] Knight, K. and Fu, W. (2000) *'Asymptotics for Lasso-type estimators',* Annals of Statistics, 28(5), pp. 1356–1378. doi: 10.1214/aos/1015957397.

[KOH 13] Kohavi, R. and John, G. H. (2013) *'Wrappers for feature subset selection',* Lecture Notes in Computer Science (including subseries Lecture Notes

in Artificial Intelligence and Lecture Notes in Bioinformatics), 7920 LNCS(97), pp. 654–678. doi: 10.1007/978-3-642-39038-8-27.

[KOK 17] Koklu, M. and Ozkan, I. A. (2017) *'Skin Lesion Classification using Machine Learning Algorithms',* International Journal of Intelligent Systems and Applications in Engineering, 4(5), pp. 285–289. doi: 10.18201/ijisae.2017534420.

[KOR 12] Korotkov, K. and Garcia, R. (2012) *'Computerized analysis of pigmented skin lesions: A review',*Artificial Intelligence in Medicine. Elsevier B.V., 56(2), pp. 69–90. doi: 10.1016/j.artmed.2012.08.002.

[KRI 07] Krizhevsky, A., Sutskever, I. and Geoffrey E. Hinton (2007) *ImageNet Classification with Deep Convolutional Neural Networks,* Handbook of Approximation Algorithms and Metaheuristics. doi: 10.1201/9781420010749.

[LAR 17] Larsson, G., Maire, M. and Shakhnarovich, G. (2019) *'FractalNet: Ultra-deep neural networks without residuals',* 5th International Conference on Learning Representations, ICLR 2017 - Conference Track Proceedings, pp. 1–11.

[LEC 05] LECUN, Y. et al. (2005) '*Gradient-Based Learning Applied to Document Recognition',* 330(4), pp. 1299–1305. doi: 10.1016/j.bbrc.2005.03.111.

[LI 14] Li, Y. et al. (2014) *'Ensemble learning',* Data Classification: Algorithms and Applications, (May), pp. 483–509. doi: 10.1201/b17320.

[LIN 14] Lin, M., Chen, Q. and Yan, S. (2014) *'Network in network',* 2nd International Conference on Learning Representations, ICLR 2014 - Conference Track Proceedings, pp. 1–10.

[LOP 17] Lopez, A. R. and Giro-i-nieto, X. (2017) 'skin lesion classification from dermoscopic images using deep learning techniques', pp. 49–54.

[LUK 15] Luckert, Michael, and Moritz Schaffer-Kehnert. 2015. "Using Machine Learning Methods for Evaluating the Quality of Technical Documents," 102.

[MA 15] Ma, Z. and Tavares, J. M. R. S. (2015) *'A Novel Approach to Segment Skin Lesions in Dermoscopic Images Based on a Deformable Model',* 2194(c), pp. 1–10. doi: 10.1109/JBHI.2015.2390032.

[MAC 67] MacQueen, James and others (1967) '*Some methods for classification and analysis of multivariate observations',* Proceedings of the fifth Berkeley symposium on mathematical statistics and probability, 1(14), pp. 281–297.

[MAC 89] Mackie, R. M., Freudenberger, T. and Aitchison, T. C. (1989) *'Personal Risk-Factor Chart for Cutaneous Melanoma',* The Lancet, 334(8661), pp. 487–490. doi: 10.1016/S0140-6736(89)92097-7.

[MAD 12] Madhankumar, K. and Kumar, P. (2012) *'Characterization of skin lesions',* International Conference on Pattern Recognition, Informatics and Medical Engineering, PRIME 2012, pp. 302–306. doi: 10.1109/ICPRIME.2012.6208362.

[MAH 09] Mahbod, A. et al. (2019) *'Skin Lesion Classification Using Hybrid Deep Neural Networks',* in ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings, pp. 1229–1233. doi: 10.1109/ICASSP.2019.8683352.

[MAH 13] Mahmoud, M. K. A. et al. (2013) 'Classification of Malignant Melanoma and Benign Nevi from Skin Lesions Based on Support Vector Machine', pp. 236–241. doi: 10.1109/cimsim.2013.45.

[MAH 15] Mahmood, A. F. (2015) *'Artifact Removal from Skin Dermoscopy Images to Support Automated* Melanoma Diagnosis Hamed Abdulaziz Mahmood, pp. 22–30.

[MAR 03] Marghoob, A. A. et al. (2003) *'Instruments and new technologies for the in vivo diagnosis of melanoma',* Journal of the American Academy of Dermatology, 49(5), pp. 777–797. doi: 10.1016/S0190-9622(03)02470-8.

[MAS 13] Masood, A. and Al-Jumaily, A. A. (2013) *'Computer aided diagnostic support system for skin cancer: a review of techniques and algorithms.',* International journal of biomedical imaging, 2013, p. 323268. doi: 10.1155/2013/323268.

[MAT 15] Mathew, S. and Sathyakala, D. (2015) *'Segmentation of skin lesions and classification by neural network',* International Journal of Advanced Research in Electronics and Communication Engineering (IJARECE) Volume 4, Issue 2, February 2015.4(2).

[MAT 17] Matsunaga, K. et al. (2017) 'Image classification of melanoma, nevus and seborrheic keratosis by deep neural network ensemble', arXiv, pp. 2–5.

[MEN 13] Mendonc, T., Ferreira, P. M. and Marques, J. S. (2013)*'PH 2 - A dermoscopic image database for research and benchmarking',* (July), pp. 1–5. doi: 10.1109/EMBC.2013.6610779.

[MEN 96] Menzies, S. W. et al. (1996) *'Frequency and morphologic characteristics of invasive melanomas lacking specific surface microscopic features',* Archives of Dermatology, 132(10), pp. 1178–1182. doi: 10.1001/archderm.132.10.1178.

[MHA 13] Mhaske, H. R. and Phalke, D. A. (2013) *'Melanoma skin cancer detection and classification based on supervised and unsupervised learning',* 2013 International Conference on Circuits, Controls and Communications, CCUBE 2013, pp. 1–5. doi: 10.1109/CCUBE.2013.6718539.

[MOG 07] Mogensen, M. and Jemec, G. B. E. (2007) 'Diagnosis of nonmelanoma skin cancer/keratinocyte carcinoma: A review of diagnostic accuracy of nonmelanoma skin cancer diagnostic tests and technologies', Dermatologic Surgery, 33(10), pp. 1158–1174. doi: 10.1111/j.1524-4725.2007.33251.x.

[MOH 13] Mohanaiah, P., Sathyanarayana, P. and Gurukumar, L. (2013) 'Image Texture Feature Extraction Using GLCM Approach', International Journal of Scientific & Research Publication, 3(5), pp. 1–5. doi: 10.1.1.414.96981.

[MOU 18] Moura, N. et al. (2018) *'Combining ABCD Rule , Texture Features and Transfer Learning in Automatic Diagnosis of Melanoma',*

IEEE Symposium on Computers and Communications (ISCC) (2018): 00508-00513.

[MUR 19] Murugan, A., Nair, S. A. H. and Kumar, K. P. S. (2019) *'Detection of Skin Cancer Using SVM , Random Forest and kNN Classifiers'*. Journal of Medical Systems.

[NAS 18] Nasir, M. et al. (2018) 'An improved strategy for skin lesion detection and classification using uniform segmentation and feature selection based approach', Microscopy Research and Technique, (December 2017). doi: 10.1002/jemt.23009.

[NGU 13] Nguyen, L. (2013) 'Overview of Bayesian Network', (October). Science Journal Of Mathematics and Statistics, Volume 2013 (2013),doi: 10.7237/sjms/105.

[NOB 06] Noble, W. S. and Street, P. (2006) "What is a support vector machine?" Nat Biotechnol. 2006 Dec;24(12):1565-7. doi: 10.1038/nbt1206-1565. PMID: 17160063.

[NOW 16] Nowroozipour, F. (2016) *'Skin Lesion Segmentation Techniques for Melanoma Diagnosis: Comparative Studies',* Electrical & Computer Engineering Toronto, Ontario, Canada, p. 62.

[OJA 00] Ojala, T., Pietikäinen, M. and Mäenpää, T. (2000) *'Gray scale and rotation invariant texture classification with local binary patterns',* Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 1842, pp. 404–420. doi: 10.1007/3-540-45054-8_27.

[OLI 04] Oliveria, S. A. et al. (2004) *'Patient adherence to skin self-examination: Effect of nurse intervention with photographs',* American Journal of Preventive Medicine, 26(2), pp. 152–155. doi: 10.1016/j.amepre.2003.10.006.

[OLI 09] Oliveira, J. R. De et al. (2009) *'Image Skeletonization Method applied to generation of Topological Maps',* 6th Latin American Robotics Symposium (LARS 2009), 2009, pp. 1-6, doi: 10.1109/LARS.2009.5418319. Oct. 29-3.

[OLI 14] Oliveira, R. B. (2014) *'features selection for the classification of skin',* 11th World Congress on Computational Mechanics (WCCM XI), 5th European Conference on Computational Mechanics (ECCM V) and 6th European Conference on Computational Fluid Dynamics.

[OLI 16] Oliveira, R. B. et al. (2016) *'A computational approach for detecting pigmented skin lesions in macroscopic images',* Expert Systems with Applications. Elsevier Ltd, 61, pp. 53–63. doi: 10.1016/j.eswa.2016.05.017.

[OOM 13] Oommachen, N. (2013) *'Melanoma Skin Cancer Detection Based on Skin Lesions Characterization',* IOSR Journal of Engineering, 03(02), pp. 52–59. doi: 10.9790/3021-03215259.

[OZK 17] Ozkan, I. A. and Koklu, M. (2017) 'Intelligent Systems and Applications in Engineering Skin Lesion Classification using Machine Learning Algorithms', pp. 1–5. doi: 10.18201/ijisae.2017534420.

[PAT 15] Patro, S. G. K. and Sahu, K. K. (2015) *'Normalization: A Preprocessing Stage',* IARJSET, pp. 20–22. doi: 10.17148/iarjset.2015.2305.

[PAT 19] Pathan, S., Prabhu, K. G. and Siddalingaswamy, P. C. (2019) 'Biomedical Signal Processing and Control Automated detection of melanocytes related pigmented skin lesions : A clinical framework', Biomedical Signal Processing and Control. Elsevier Ltd, 51, pp. 59–72. doi: 10.1016/j.bspc.2019.02.013.

[QUI 86] Quinlan, J. R. (1986) *'Induction of decision trees',* Machine Learning, 1(1), pp. 81–106. doi: 10.1007/bf00116251.

[RAH 07] Rahman, U. T. a. (2007) 'Gabor filters and gray level co occurrence matrices in texture classification', Citeseer. Available at: http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.140.4766&rep=rep1&type=pdf.

[RAI 05] Rai, R., Shukla, S. and Singh, B. (2005) 'Histograms of Oriented Gradients for Human Detection', IEEE Transactions on Industrial Informatics, 16(7), pp. 4714–4725. doi: 10.1109/TII.2019.2950094.

[ROK 14] Rokach, L. (2014) *'decision trees',* Research gate, (November), pp. 0–11. doi: 10.1007/0-387-25465-X.

[SAB 14] Sabouri, P., GholamHosseini, H. and Collins, J. (2014) *'Border detection of skin lesions on a single system on chip',* Lecture Notes in Electrical Engineering, 260 LNEE, pp. 465–471. doi: 10.1007/978-94-007-7262-5_53.

[SAE 07] Saeys, Y., Inza, I. and Larrañaga, P. (2007) *'A review of feature selection techniques in bioinformatics',* Bioinformatics, 23(19), pp. 2507–2517. doi: 10.1093/bioinformatics/btm344.

[SAH 16] Saha, P. K., Borgefors, G. and Sanniti, G. (2016) *'A survey on skeletonization algorithms and their applications',* Pattern Recognition Letters. Elsevier Ltd., 76, pp. 3–12. doi: 10.1016/j.patrec.2015.04.006.

[SAL 18a] Salido, J. A. N. N. and Jr, C. R. (2018) *'hair artifact removal and skin lesion segmentation of dermoscopy images',* Asian Journal of Pharmaceutical and Clinical Research 11(15):36 11(3), pp. 2–5.

[SAL 18b] Salido, J. A. A. and Jr, C. R. (2018) *'Using Deep Learning for Melanoma Detection in Dermoscopy Images',* (February). International Journal of Machine Learning and Computing, Vol. 8, No. 1, doi: 10.18178/ijmlc.2018.8.1.664.

[SAM 13] Smaoui, N. and Bessassi, S. (2013) *'A developed system for melanoma diagnosis',* International Journal of Computer Vision and Signal Processing, 3(1), pp. 10–17.

[SCH 13] Schaefer, G. et al. (2013) *'Melanoma Classification using Dermoscopy Imaging and Ensemble Learning'*. 2nd IAPR Asian Conference on Pattern Recognition, 2013, pp. 386-390,doi: 10.1109/ACPR.2013.102.

[SIM 15] Simonyan, K. and Zisserman, A. (2015) *'very deep convolutional networks for large-scale image recognition',* arXiv preprint arXiv:1409.1556 pp. 1–14.

[SIN 10] Singh, D. Y. And Chauhan, A. S. (2010) *'neural networks in data mining',* Data Mining and Knowledge Discovery Handbook, (July 2010). doi: 10.1007/978-0-387-09823-4.

[SIE 20] Siegel, R. L., Miller, K. D. and Jemal, A. (2020) 'Cancer statistics, 2020', CA: A Cancer Journal for Clinicians, 70(1), pp. 7–30. doi: 10.3322/caac.21590.

[SPR 15] Springenberg, J. T. et al. (2015) 'Striving for simplicity: The all convolutional net', 3rd International Conference on Learning Representations, ICLR 2015 - Workshop Track Proceedings, pp. 1–14.

[SRE 19] Sreelatha, T., Subramanyam, M. V and Prasad, M. N. G. (2019) *'Early Detection of Skin Cancer Using Melanoma Segmentation technique'.* Journal of Medical Systems, pp. 1–7.

[SRI 18] Srividya, T. D. and Arulmozhi, V. (2018) 'Detection of skin cancer - A genetic algorithm approach', 7, pp. 131–135.

[STE 08] Steinwart, I. and Christman, A. (2008) *Support Vector Machines,* World Journal of Gastroenterology. doi: 10.1007/978-0-387-77242-4.

[SZE 14] Szegedy, C. et al. (2014) *'Going Deeper with Convolutions'* In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1–9).

[TAK 14] Takruri, M., Al-Jumaily, A. and Mahmoud, M. K. A. (2014) *'Automatic recognition of melanoma using Support Vector Machines: A study based on Wavelet, Curvelet and color features',* Proceedings - International Conference on Industrial Automation, Information and Communications Technology, IAICT 2014, (August), pp. 70–75. doi: 10.1109/IAICT.2014.6922110.

[THO 98] Thomas, L.; Tranchand, P.; Berard, F. et. al. (1998) 'Semiological Value of ABCDE Criteria in the Diagnosis of', Dermatology, 02, pp. 11–17.

[VIC 17] Victor, A. and Ghalib, M. R. (2017) *'Automatic detection and classification of skin cancer',* International Journal of Intelligent Engineering and Systems, 10(3), pp. 444–451. doi: 10.22266/ijies2017.0630.50.

[VIS 15] Visalakshi, S. and Radha, V. (2015) *'A literature review of feature selection techniques and applications: Review of feature selection in data mining',* 2014 IEEE International Conference on Computational Intelligence and Computing Research, IEEE ICCIC 2014, (1997). doi: 10.1109/ICCIC.2014.7238499.

[WAH 17] Waheed, Z. (2017) *'An Efficient Machine Learning Approach for the Detection of Melanoma using Dermoscopic Images',* International Conference on Communication, Computing and Digital Systems (C-CODE), 2017, pp. 316-319, doi: 10.1109/C-CODE.2017.7918949. pp. 316–319.

[ZAG 16] Zagoruyko, S. and Komodakis, N. (2016) 'Wide Residual Networks', British Machine Vision Conference 2016, BMVC 2016, 2016–Septe, p. 87.1-87.12. doi: 10.5244/C.30.87.

[ZEI 14] Zeiler, M. D. and Fergus, R. (2014) 'Visualizing and understanding convolutional networks', Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in

Bioinformatics), 8689 LNCS(PART 1), pp. 818–833. doi: 10.1007/978-3-319-10590-1_53.

[ZHO 10] Zhou, H. et al. (2010) 'Skin lesion segmentation using an improved snake model.', Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference, 2010(1), pp. 1974–7. doi: 10.1109/IEMBS.2010.5627556.

[ZHU 14] Zhu, S., Yang, J. and Zhu, X. (2014) 'A Thinning Model for Handwriting-Like Image Skeleton', pp. 687–693. doi: 10.1007/978-3-319-01766-2.

[ZOU 06] Zou, H. (2006) 'The adaptive lasso and its oracle properties', Journal of the American Statistical Association, 101(476), pp. 1418–1429. doi: 10.1198/016214506000000735.

World Health Organization. Available at: https://www.who.int/uv/faq/skincancer/en/index1.html (Accessed: 14 May 2020).

Liste des contributions

1. Articles :

1. Youssef Filali, EL Khoukhi, H., Sabri, M.A. et Aarab, A. *Efficient fusion of handcrafted and pre-trained CNNs features to classify melanoma skin cancer.* Multimed Tools Appl (2020). https://doi.org/10.1007/s11042-020-09637-4
2. Youssef Filali, My Abdelouahed Sabri and Abdellah Aarab. (2020) *Efficient skin cancer diagnosis based on deep learning approach using lesions skeleton.* Has been accepted for publication in Int. J. Cloud Computing
3. Youssef Filali, Hasnae El Khoukhi, My Abdelouahed Sabri, Ali Yahyaouy and Abdellah Aarab. *"New and Efficient Features for Skin Lesion Classification based on Skeletonization".* Journal of Computer Science. DOI: 10.3844/jcssp.2019.1225.1236. Septembre 2019, Volume 15, Issue 9. pp 1225.1236.
4. Youssef Filali, My Abdelouahed Sabri and Abdellah Aarab. *"An Improved Segmentation Approach for Skin Lesion Classification". Statistics, Optimization & Information Computing. DOI:* 10.19139/soic.v7i2.533. May 2019, Volume 7, Numéro 2, pp 456-467.
5. Khoukhi, H.E., Filali, Y., Sabri, M.A., Aarab, A. (2020). *Design and implementation of content-based image retrieval on fpga card.* International Journal of Advanced Trends in Computer Science and Engineering, 9 (5), pp. 8085-8093. https://10.0.119.70/ijatcse/2020/169952020.

2. Chapitres :

1. Sabri M.A., Filali Y., Fathi S., Aarab A. (2021) Detection, Analysis and Classification of Skin Lesions: Challenges and Opportunities. In: Gherabi N., Kacprzyk J. (eds) Intelligent Systems in Big Data, Semantic Web and Machine Learning. Advances in Intelligent Systems and Computing, vol 1344. Springer, Cham. https://doi.org/10.1007/978-3-030-72588-4_14
2. Sabri, My Abdelouahed, Filali, Youssef, Ennouni, Assia, Yahyaouy, Ali and Aarab, Abdellah." An overview of skin lesion segmentation, features engineering, and classification" Intelligent Decision Support Systems: Applications in Signal Processing (pp. 31–52). Berlin, Boston: De Gruyter. https://doi.org/10.1515/9783110621105-002. ISBN: 9783110621105

3. Conférences :

1. Ibrahim K., Filali Y., Sabri M.A., Aarab A. (2021) Embedded Skin Cancer Detection and Classification on Raspberry Pi. In: Masrour T., El Hassani I., Cherrafi A. (eds) Artificial Intelligence and Industrial Applications. A2IA

2020. Lecture Notes in Networks and Systems, vol 144. Springer, Cham. https://doi.org/10.1007/978-3-030-53970-2_28

2. Filali Y., Sabri M.A., Aarab A. (2020) Improving Skin Cancer Classification Based on Features Fusion and Selection. In: Bhateja V., Satapathy S., Satori H. (eds) Embedded Systems and Artificial Intelligence. Advances in Intelligent Systems and Computing, vol 1076. Springer, Singapore. https://doi.org/10.1007/978-981-15-0947-6_36

3. M. A. Sabri, Y. Filali, H. El Khoukhi and A. Aarab, "Skin Cancer Diagnosis Using an Improved Ensemble Machine Learning model," 2020 International Conference on Intelligent Systems and Computer Vision (ISCV), Fez, Morocco, 2020, pp. 1-5, doi: 10.1109/ISCV49265.2020.9204324.

4. H. El Khoukhi, Y. Filali, A. Yahyaouy, M. A. Sabri and A. Aarab, "A hardware Implementation of OTSU Thresholding Method for Skin Cancer Image Segmentation," 2019 International Conference on Wireless Technologies, Embedded and Intelligent Systems (WITS), April 03-04, Fez, Morocco, 2019, pp. 1-5. doi: 10.1109/WITS.2019.8723815.

5. Y. Filali, H. El Khoukhi, M. A. Sabri, A. Yahyaouy and A. Aarab, "Texture Classification of skin lesion using convolutional neural network," 2019 International Conference on Wireless Technologies, Embedded and Intelligent Systems (WITS), April 03-04, Fez, Morocco, 2019, pp. 1-5. doi: 10.1109/WITS.2019.8723791

6. Youssef Filali; Assia Ennouni; My Abdelouahed Sabri; Abdellah Aarab. "A study of lesion skin segmentation, features selection and classification approaches," 2018 International Conference on Intelligent Systems and Computer Vision (ISCV). Pages: 1-4. ISBN: 978-1-5386-4396-9. DOI: 10.1109/ISACV.2018.8354069. 2-4 April 2018. Fez, Morocco.

7. Youssef Filali; My Abdelouahed Sabri; Abdellah Aarab. "An improved approach for skin lesion analysis based on multiscale decomposition". 2017 International Conference on Electrical and Information Technologies (ICEIT). ISBN: 978-1-5386-1516-4. DOI: 10.1109/EITech.2017.8255250. 15-18 Nov. 2017. Rabat, Morocco.

8. Youssef Filali; Assia Ennouni; My Abdelouahed Sabri; Abdellah Aarab. "Multiscale approach for skin lesion analysis and classification". 2017 International Conference on Advanced Technologies for Signal and Image Processing (ATSIP). ISBN: 978-1-5386-0551-6. DOI: 10.1109/ATSIP.2017.8075545. 22-24 May 2017. Fez, Morocco.

9. Assia Ennouni; Youssef Filali; My Abdelouahed Sabri; Abdellah Aarab. "A review on image mining". 2017 Intelligent Systems and Computer Vision (ISCV). pp. 1-7. Print on Demand(PoD) ISBN: 978-1-5090-4063-6. Electronic ISBN: 978-1-5090-

4062-9. DOI: 10.1109/ISACV.2017.8054916. 17-19 April 2017. Fez, Morocco