



HAL
open science

Apprentissage profond pour l'aide au diagnostic du mélanome à partir d'exemple

Arthur Cartel Foahom Gouabou, Frédéric Heim, Jean-Luc Damoiseaux

► To cite this version:

Arthur Cartel Foahom Gouabou, Frédéric Heim, Jean-Luc Damoiseaux. Apprentissage profond pour l'aide au diagnostic du mélanome à partir d'exemple. [Rapport de recherche] Université de Haute-Alsace. 2019. hal-02515203

HAL Id: hal-02515203

<https://amu.hal.science/hal-02515203v1>

Submitted on 23 Mar 2020

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Rapport de Stage

de M. Arthur Cartel Foahom Gouabou

En vue de l'obtention du GRADE de Master 2

Promotion 2018 - 2019

**« Apprentissage profond pour l'aide au diagnostic du
mélanome à partir d'exemple »**

Tuteur pédagogique

M. Frédéric Heim

Tuteur professionnel

M. Jean-Luc Damoiseaux

Fiche archivage pour la bibliothèque universitaire

I.L'étudiant

Nom : FOAHOM GOUABOU

Prénom : Arthur Cartel

Année Universitaire : 2018-2019

Diplôme préparé : Master 2

II.L'entreprise

Dénomination de l'entreprise : Université Aix-Marseille

Adresse complète : Jardin du pharo 58, Bld Charles Livon 13007 Marseille 7^{ème}

Pays : France

Secteur d'activité : Informatique

Type d'entreprise: Administration

Nombre de salariés : 200 à 999

Nombre de cadres :

III.Le rapport de stage

Titre du rapport de stage : Apprentissage profond pour l'aide au diagnostic du mélanome à partir d'exemple

Mots-clés : Diagnostique du mélanome, Machine à vecteurs de support, apprentissage profond, extracteur de caractéristiques.

Résumé:

Une étude révèle que 15404 nouveaux cas de mélanomes cutanés ont été estimés en France en 2017. Le taux de survie à 5 ans d'une personne atteinte d'un mélanome à un stade avancé est très inférieure à 20% ce qui pose la nécessité de le diagnostiquer à un stade précoce. Ce travail a pour objectif de construire de manière supervisée un système de diagnostic assisté par ordinateur du mélanome. La base de données utilisée pour l'implémentation comporte 1356 images réparties en 9 classes. Deux approches sont abordées pour cela : une approche classique et une approche par apprentissage profond. L'approche classique combine deux classifieurs à machine à vecteur de support (MVS) entraînés sur des fonctionnalités extraites de trois extracteurs. Cette approche a donné une aire sous la courbe du récepteur (AED-CCR) de 0.88, une sensibilité (SE) de 89% et une spécificité (SPEC) de 77%. L'approche par apprentissage profond utilise des fonctionnalités extraites de deux modèles pré-entraînés VGG16 et resnet50 pour entraîner deux MVS. Les scores issus de ces deux classifieurs sont combinés grâce à un algorithme de régression logistique pour obtenir la classification. Cette approche a donné un AED-CCR de 0.88, une SE de 78% et une SPEC de 83%.

Abstract :

One study reveals that 15404 new cases of cutaneous melanoma have been estimated in France in 2017. The 5-year survival rate of a person with advanced melanoma is much lower than 20%, which raises the need for diagnose it at an early stage. The purpose of this work is to build a supervised computer-aided diagnosis system for melanoma. The database used for the implementation includes 1356 images divided into 9 classes. Two approaches have been implemented : classical approach and deep learning approach. The classical approach combines two support vector machine classifiers (SVM) trained on features extracted from three extractors. This approach yielded an area under the receptor curve (AUC) of 0.88, a sensitivity (SE) of 89% and a specificity (SPEC) of 77%. The deep learning approach uses features extracted from two pre-trained models VGG16 and resnet50 to train two linear SVM. The scores from these two classifiers are combined using a logistic regression algorithm to obtain the classification. This approach yielded an AED-CCR of 0.88, SE of 78% and SPEC of 83%.

IV.Diffusion

- le contenu n'est pas confidentiel, diffusion immédiate du rapport.
 le contenu est confidentiel, diffusion du rapport après une période d'attente de * :

1 an. 2 ans 3 ans 5 ans 10 ans

Approbations et diffusion par l'entreprise

V. Identifications

Nom et prénom du tuteur professionnel

Jean-Luc DAMOISEAUX

Nom et prénom du stagiaire

Arthur Cartel FOAHOM GOUABOU

Nom de l'organisation

Université d'Aix- Marseille

VI. Approbation de diffusion

J'atteste par la présente avoir pris connaissance du rapport de stage de fin d'études et donne mon accord pour son envoi au jury de soutenance.

VII. Reconnaissance de la clause de non plagiat

Je reconnais avoir pris connaissance du formulaire d'information sur le plagiat, contenu dans le présent rapport.

VIII. Accord de diffusion

Suite à l'accord entre l'Université de Haute Alsace et la Bibliothèque de l'Université, après audition du stagiaire, le rapport sera confié à la bibliothèque qui en assurera le stockage et la valorisation.

- le contenu n'est pas confidentiel, j'autorise la diffusion immédiate du rapport. *
- le contenu est confidentiel, j'autorise la diffusion du rapport après une période d'attente de * :

1 an. 2 ans 3 ans 5 ans 10 ans

Fait à Marseille

Le 18/08/2019

Signature :

Formulaire d'information sur le plagiat

Dans le règlement des examens validé par la CFVU du 2 octobre 2014, le plagiat est assimilé à une fraude.

Le plagiat consiste à reproduire un texte, une partie d'un texte, des données ou des images, toute production (texte ou image), ou à paraphraser un texte sans indiquer la provenance ou l'auteur. Le plagiat enfreint les règles de la déontologie universitaire et il constitue une fraude. Le plagiat constitue également une atteinte au droit d'auteur et à la propriété intellectuelle, susceptible d'être assimilé à un délit de contrefaçon.

En cas de plagiat dans un devoir, dossier, mémoire ou thèse, l'étudiant sera présenté à la section disciplinaire de l'université qui pourra prononcer des sanctions allant de l'avertissement à l'exclusion.

Dans le cas où le plagiat est aussi caractérisé comme étant une contrefaçon, d'éventuelles poursuites judiciaires pourront s'ajouter à la procédure disciplinaire.

Je soussigné(e) **Arthur Cartel Foahom Gouabou**

Etudiant(e) à l'Université de Haute Alsace en : **Master mécanique**

Niveau d'études : **Master 2**

Formation ou parcours : **Ingénierie du véhicule et mécatronique**

Reconnaît avoir pris connaissance du formulaire d'information sur le plagiat.

Fait à **Marseille**

Le **12/08/2019**

Signature :

Sommaire

Fiche archivage pour la bibliothèque universitaire	2
I. L'étudiant.....	2
II. L'entreprise	2
III. Le rapport de stage	2
IV. Diffusion	3
Approbations et diffusion par l'entreprise	3
V. Identifications	4
VI. Approbation de diffusion	4
VII. Reconnaissance de la clause de non plagiat	4
VIII. Accord de diffusion.....	4
Formulaire d'information sur le plagiat.....	5
Sommaire	6
Remerciements	7
Introduction.....	8
Chapitre I : Le diagnostic assisté par ordinateur du mélanome.....	9
I.1 Le cancer du mélanome	9
I.2 Diagnostic assisté par ordinateur (DAO)	11
I.2.1 Description de la construction d'un DAO pour l'analyse d'image.....	11
I.2.2 Revue des méthodes récentes de conception de DAO des cancers de la peau.....	13
Chapitre II : Méthodes.....	15
II.1 La base de données et les critères de performances du modèle.....	15
II.1.1 La base de données	15
II.1.2 Evaluation de la performance du DAO	16
II.2 Approche classique.....	16
II.2.1 Le prétraitement	17
II.2.2 Extraction de fonctionnalités	17
II.2.3 Classification.....	18
II.3 Approche par apprentissage profond	19
II.3.1 Pré-entraînement et extraction de fonctionnalité.....	19
II.3.2 Classification.....	20
II.4 Outils et matériels	20
Chapitre III : Résultats et discussion.....	21
III.1 Approche classique.....	21
III.2 Approche par apprentissage profond	24
Conclusion	26

Remerciements

Nous rendons grâce à Dieu tout puissant pour ses grâces, le souffle de vie, la santé, l'intelligence et le courage qu'il nous a donné et qui nous a accompagné tout le long de cette année d'étude jusqu'à l'aboutissement de ce travail.

Aussi nous tenons à exprimer notre gratitude à ceux et celles qui par leur assistance morale et physique, par leur expérience, leur sympathie, leur encouragement, leur collaboration et leur disponibilité ont contribué de près ou de loin à la réalisation de ce travail. Nous pensons particulièrement à :

☞ A Monsieur Jean-Luc Damoiseaux notre encadrant pour sa disponibilité et son orientation dans la réalisation de ce projet.

☞ A Monsieur Djamal Merad pour son attention sur nos travaux et pour ses conseils.

☞ A Monsieur Frederic Heim notre encadrant académique et responsable de master pour notre formation.

☞ A Monsieur Bernard Fertil et Thierno Balde de la startup Anapix pour leurs remarques et suggestions constructives.

☞ A toute l'équipe I&M du laboratoire LIS avec qui nous échangeons régulièrement, plus particulièrement Rabah Iguernaissi, Raphael Abele et Thibault Payet.

☞ A mes camarades et amis de promotion Lionel et Youssouf pour les encouragements et les rires.

☞ A ma copine Estelle pour son soutien moral et ses conseils.

☞ A mon frère Alain et son épouse Jennifer qui m'ont accueilli et accompagné tout le long de ma formation.

☞ A ma sœur Ariane qui n'a ménagé aucun effort pour me permettre de poursuivre mes études de master.

☞ A mes parents Clotilde et Bernard et ma soeur Blondelle pour leur soutien constant.

A tous ceux et celles que nous oublions, qu'ils trouvent ici la marque de notre profonde sympathie.

Introduction

Les cancers en général et plus particulièrement les cancers de la peau représentent un problème majeur de santé publique de par le nombre de décès dus à ces maladies. Le nombre de nouveaux cas annuels de mélanomes augmente de 5% par an depuis 50 ans, une croissance supérieure à celle de tout autre cancer. Si le diagnostic intervient tôt dans l'évolution de la lésion, le taux de survie relative à 5 ans est de 88% pour les stades localisés. A contrario, la survie à 5 ans d'une personne atteinte d'un mélanome à un stade avancé, avec des métastases est inférieure à 20% [1,2]. Détecter un mélanome à un stade précoce, alors que relativement peu de signes de malignité sont visibles sur la lésion est donc très souhaitable, mais cette opération est difficile. Les travaux de recherche menés précédemment dans l'équipe I&M ont montré que les classifieurs automatiques basés sur des modèles de machines à vecteurs de support (MVS) sont plus efficaces que les humains pour le diagnostic des lésions atypiques[1]. Des travaux récents[2] fondés sur une approche par apprentissage profond (Deep learning) arrivent à la même conclusion et surpassent 21 dermatologues pour le diagnostic des cancers de la peau.

Ce travail a pour objectif de construire de manière supervisée un système de diagnostic assisté par ordinateur (DAO) du mélanome. Le but est d'établir un classifieur qui puisse différencier à partir d'une image une lésion maligne d'une lésion bénigne.

Pour mener à bien notre projet, la démarche employée, à partir de consultations documentaires et de personnes ressources, sera tout d'abord de faire une revue scientifique des techniques de construction de système de diagnostic assisté par ordinateur. Ensuite, à partir des résultats de nos recherches, nous nous attèlerons à construire des modèles pertinents qui répondent au mieux aux besoins du dermatologue. Ce travail est destiné aux étudiants et chercheurs dans le domaine des sciences de données et d'apprentissage automatique.

Ce mémoire est subdivisé en trois chapitres : le premier chapitre fait une revue de littérature des techniques récentes de construction de système de diagnostic, le deuxième chapitre présente notre contribution dans la construction du système à proprement parlé et le dernière chapitre expose les résultats commentés de nos implémentations.

Chapitre I : Le diagnostic assisté par ordinateur du mélanome

Depuis des décennies, une grande partie de la communauté scientifique se penche sur la recherche de solutions visant à réduire le problème majeur de santé publique que représente les cancers de la peau. Ce chapitre présente le contexte du sujet d'étude et décrit les différentes méthodologies de conception de système de diagnostic assisté par ordinateur retrouvées dans la littérature.

I.1 Le cancer du mélanome

Il existe trois principaux types de cancers de la peau : le carcinome basocellulaire, le carcinome épidermoïde et le mélanome. Bien qu'il ne représente que 4% des cancers de la peau, le mélanome est responsable de 80% des décès dus à un cancer cutané dans le monde. En France métropolitaine, 15404 nouveaux cas de mélanomes cutanés ont été estimés en 2017 (8061 hommes et 7343 femmes) avec un taux de survie relative à 5 ans de 91%. Par contre, ce taux présente de grandes variations en fonction du stade d'évolution de la lésion. Pour des stades localisés, ce taux se situe entre 40% et 98%, tandis que pour des personnes atteintes d'un mélanome à un stade avancé avec des métastases, leur taux de survie varie entre 9% et 19%. Les principaux facteurs de risque de mélanome sont liés à l'exposition solaire, mais aussi à des facteurs génétiques tels que les antécédents familiaux, le nombre de nævus¹ ou le phototype² clair[3, 4].

La première étape de l'examen clinique des lésions mélanocytaires est l'examen dermoscopique. Dans la littérature dermatologique, il existe plusieurs méthodes permettant au dermatologue d'effectuer le diagnostic du mélanome. Les plus utilisées sont la règle ABCDE et les 7 points de la liste de contrôle. Le principe de base de ces méthodes consiste tout d'abord en l'identification d'un certain nombre de caractéristiques prédéfinies, ensuite à une classification des lésions analysées selon qu'elles sont malignes ou bénignes.

❖ La règle ABCDE

La règle ABCDE définit cinq critères déterminant pour le diagnostic du mélanome, l'asymétrie(A), la Bordure(B) irrégulière, la couleur(C) inhomogène, le diamètre(D) supérieur à 6 mm et l'évolutivité(E) récente. Chaque critère est ensuite multiplié par un coefficient afin d'établir le score dermoscopique total (SDT). La valeur du SDT est ensuite comparée avec des

¹ Naevus ou grain de beauté est une petite tache de forme généralement circulaire ou ovale située sur le dessus de la peau

² Élément de classification des individus selon la réaction de leur peau à une exposition solaire

valeurs prédéfinies afin d'effectuer la classification. Pour un SDT < 4.7 , la lésion est considérée bénigne, pour un SDT > 5.45 , la lésion est considérée maligne et pour un SDT compris entre 4.7 et 5.45, la lésion est considérée suspecte[4, 5].

❖ Les 7 points de la liste de contrôle

Cette méthode repose sur 7 critères répartis en deux catégories : les critères majoritaires et les critères minoritaires. Les critères majoritaires sont : la présence ou non de réseaux pigmentaires atypiques, de voiles bleu-blanc et de motifs vasculaires atypiques. Les critères minoritaires sont : la présence ou non de stries irréguliers, de pigmentations irrégulières, de points/globule irréguliers et de structure de régression. La *figure1* illustre ces critères[6]. De la même manière que la règle ABCDE, un score global est calculé en affectant un coefficient de deux points aux critères majoritaires et un coefficient de un point aux critères non majoritaires. Pour un score global supérieur ou égal à 3 la lésion sera considéré maligne et bénigne dans le cas contraire.




Figure 1 : Examen dermoscopique. Illustration des critères utilisés dans la méthode des 7 points de la liste de contrôle[6].

Une fois le diagnostic posé, le dermatologue peut demander un examen histologique de la lésion après une biopsie³ afin de le confirmer.

Au fil des années, des études et des expériences ont été menées afin d'évaluer la performance des méthodes de diagnostic du mélanome, notamment celle de la règle ABCDE et des 7 points de la liste de contrôle. S'agissant de la règle ABCDE, le problème de l'universalité des coefficients utilisés dans le SDT ainsi que le seuil de décision défini a été posé. En effet, Lorentzen[7], dans ses travaux, révèle la flexibilité du choix du seuil de décision qui n'impacte pas sur la spécificité et la sensibilité du diagnostic, ce qui met en doute l'optimalité des

³ Prélèvement d'une très petite partie d'un organe ou d'un tissu pour effectuer des examens concernant un être vivant.

paramètres de la règle ABCDE. De plus, Johr[8] dans ses travaux réalise une analyse des études effectuées afin de comparer les performances des différentes méthodes de diagnostic, il ressort de cela que leur efficacité dépend grandement d'un certain nombre de paramètres tels que le niveau d'expérience du dermatologue, la taille de la lésion et le type de population entre autres. Au vu de cela, la communauté scientifique s'est penchée sur le développement de système automatique d'analyse d'image afin d'augmenter la précision des diagnostics. Les travaux de recherche dans ce sens ont donné des résultats satisfaisants.

I.2 Diagnostic assisté par ordinateur (DAO)

Malgré l'avancée des technologies notamment via l'examen dermoscopique et l'application des méthodes de diagnostic présentées précédemment, le diagnostic du mélanome de façon *in vivo*⁴ demeure difficile. C'est ainsi que le diagnostic assisté par ordinateur du mélanome a été introduit afin d'améliorer la reproductibilité du jugement clinique et aider les dermatologues et d'autres cliniciens inexpérimentés avec un deuxième avis. La construction d'un DAO repose principalement sur quatre étapes : Le prétraitement de l'image, la segmentation, l'extraction des fonctionnalités et la classification. La *figure 2* présente le diagramme block d'un DAO de mélanome.



Figure2 : Diagramme block d'un DAO

I.2.1 Description de la construction d'un DAO pour l'analyse d'image

❖ Le prétraitement de l'image

Le prétraitement de l'image est une étape importante, dans la mesure où les images des lésions obtenues à partir d'une caméra ou d'un dermoscope contiennent des éléments qui peuvent fausser l'étape de segmentation et d'extraction de fonctionnalités. Il s'agit entre autre des brins de cheveux, des bulles d'air et d'une illumination non uniforme. Des exemples d'approches visant à éliminer ces occlusions comprennent des approches classiques telles que l'algorithme DullRazor, le filtrage médian et directionnel et l'amélioration de l'éclairage[9-12], ou des approches plus récentes à l'instar de celui de Bisla[13] qui a construit un modèle dénommé « Data purification network » à base de l'architecture U-net[14] pour éliminer les occlusions.

⁴ Non invasive de structures cutanées

❖ La segmentation de la lésion

L'objectif principal de l'étape de segmentation est de séparer la région de l'image contenant la lésion du reste de la peau. Les travaux réalisés sur la comparaison des performances des différentes techniques de segmentation, présentés dans les articles [15-17], démontrent la contribution de cette étape dans l'amélioration de la précision d'un système DAO, notamment de la sensibilité. Néanmoins, cette étape demeure l'une des plus complexes en imagerie médicale. Chang[18] par exemple explique qu'il est impossible de procéder à une segmentation automatique de toutes les images de lésions cutanées pour des raisons comme la complexité d'acquisition de ces images. Cependant, Adeyinka[17] affirme que les techniques basées sur l'apprentissage profond sont les plus performantes dans la segmentation des images des lésions de la peau.

❖ L'extraction des fonctionnalités

Une fois la segmentation de l'image effectuée, la prochaine étape est celle de l'extraction de fonctionnalités qui représentent les informations importantes pour l'étape de classification. Nasir[19] décrit les fonctionnalités les plus importantes et les plus utilisées pour la classification des lésions mélanocytaires comme étant la couleur, la texture et la forme. Ces fonctionnalités s'inspirent des approches cliniques de diagnostic présentées à la **section I.1**. Au-delà de l'extraction des fonctionnalités, une procédure de sélection est souvent appliquée afin de retenir les fonctionnalités les plus pertinentes et de ce fait réduire le nombre de caractéristiques qui seront utilisées pour la prochaine étape. Celebi[10] énumère les avantages de cette procédure, tandis que Oliviera[20] présente les méthodes de sélection de fonctionnalités les plus utilisées à l'instar de l'analyse en composantes principales, l'analyse discriminante linéaire et la sélection de caractéristiques basée sur la corrélation.

❖ La classification

La classification est la dernière étape dans la construction d'un DAO. Son objectif est de reconnaître et d'interpréter les informations à propos des lésions de la peau en se basant sur les fonctionnalités extraites des images. Les problèmes auxquels le concepteur peut faire face lors de cette étape sont le déséquilibre de la base de données, un nombre important de fonctionnalités, et des variations importantes des plages des valeurs des fonctionnalités[20]. La littérature a rapporté l'application de plusieurs méthodes de classification pour les images de lésion. Les méthodes les plus fréquemment utilisées peuvent être classées en termes d'approches. Nous aurons pour cela l'approche par apprentissage par instance (K-plus proche

voisin), l'approche par apprentissage bayésien, l'approche par apprentissage par réseaux de neurones artificiels, l'approche par les arbres de décision, l'approche par les machines à vecteurs de support et l'approche par apprentissage profond[20-23]. Les approches par apprentissage profond semblent, selon [24-26], être les plus prometteuses.

I.2.2 Revue des méthodes récentes de conception de DAO des cancers de la peau

Dans la littérature, bon nombre de travaux ont été effectués sur la conception de système automatique d'analyse et de classification des lésions pigmentées de la peau. Dans le cadre de notre stage, nous nous orienterons vers ceux qui implémentent une approche par apprentissage profond.

Brinker[25] fait un état de l'art des méthodes de classification des lésions de la peau à partir des réseaux de neurones à convolution(RNC). Il en découle deux principaux types d'approche d'utilisation des RNC, la première consiste à utiliser les RNC comme un extracteur de fonctionnalités, et dans ce cas, la classification est réalisée par un autre classifieur. La deuxième approche consiste à directement faire apprendre de bout en bout le RNC. Contrairement aux méthodes classiques généralement appliquées dans la classification automatique, cette dernière approche inclut dore et déjà l'extraction de fonctionnalités. Cette dernière approche peut elle-même être divisée en deux approches : apprendre le modèle à partir de zéro ou effectuer un transfert d'apprentissage. Mahbod[27] par exemple utilise les RNC comme extracteur de fonctionnalités. Il propose une approche hybride de classification de lésion de la peau en effectuant la fusion des probabilités obtenues de trois classifieurs SVM ayant été entraîné à partir de fonctionnalités extraites par trois modèles de réseaux profond pré-entraînés, AlexNet[28], VGG16[29] et ResNet[30]. Il en ressort que la fusion de plusieurs RNCs donne de meilleurs résultats que l'utilisation d'un seul RNC. Afin d'améliorer ses résultats, il propose d'étendre le nombre de modèles pré-entraînés utilisés, mais aussi d'augmenter la taille des images. Esteva[2] par contre a eu une approche bout en bout. Il a utilisé un réseau RNC basé sur l'architecture googleNet inception v3[31], entraîné de manière directe à partir d'images (129450 images cliniques donc 2 032 types de lésions), en utilisant uniquement les pixels et les étiquettes de maladie. Il obtient avec ce modèle une précision de 72,1% dans la classification du mélanome, ce qui s'avère supérieure à celle obtenu par 21 dermatologues (66%) sur des images cliniques prouvées par biopsie. Lopez[32] propose un modèle construit à partir de l'architecture VGGNet en utilisant une approche de transfert d'apprentissage pour réaliser une classification binaire des lésions mélanocytaires. Sur une base de données de 1279 images, il a obtenu une sensibilité de 78.6% et une précision de 81.3%. Au-delà du choix des approches, la classification multi-classes est un thème qui est également

abordée dans la littérature. Kawahara[33, 34], par exemple, démontre que les RCNs peuvent être utilisés efficacement pour des classifications en multi-classes (10 classes) et ils surpassent (précision 81,8%) les techniques de pointe actuelles sans segmentation préalable des images. Zhang[35] a quant à lui utilisé un réseau d'apprentissage profond pour classifier 4 types de lésion de la peau à partir d'images dermoscopiques. Il a sur une base de 1067 images, atteint une précision de 87.25%. Dans une quête perpétuelle d'amélioration des performances des modèles, d'autres aspects au-delà du simple choix des approches ou du type de classification ont été abordés par les scientifiques. Bisla[13] par exemple, fait le constat que l'application des approches par apprentissage profond, bien que présentant de meilleures précisions et ayant un grand potentiel d'évolution, d'une part fait face aux faits que la taille des bases de données publiques disponibles n'est pas conséquente, et d'autre part qu'elles contiennent beaucoup d'occlusions et présentent généralement un gros déséquilibre entre les différentes classes. Il propose donc afin de remédier à cela, une combinaison d'un modèle entraîné à base de l'architecture U-net pour éliminer les occlusions sur les images et d'un modèle basé sur une technique de génération de donnée DCGAN[36] (Deep convolutional generative adversarial networks) afin de réduire le déséquilibre des proportions des données de chaque classe. Dans le même sens, Barata[37] fait le constat que les conditions d'acquisition des images à placer en entrée d'un DAO sont importantes, ce qui rend dépendant la performance de celui-ci par rapport aux sources de ces images. Il propose, afin de résoudre cela, des techniques de compensation de couleur, qui, appliquées à un classifieur 'Bag of features', ont amélioré de 14% ses performances. D'autres techniques ont également été développées afin d'améliorer les performances des RCNs dans la localisation d'une région précise d'une image, et de fait, permettre aux RCNs d'aller au-delà du simple étiquetage des classes d'appartenance des images. C'est le cas de la technique générale appelée mappage d'activation de classe pour les réseaux à convolution proposée par Zhou[38]. Jia[39] a d'ailleurs utilisé ces travaux afin de développer un framework permettant d'analyser des images des lésions de la peau. Il s'est pour cela servi de la base de données d'image ISIC-2017 et a utilisé un réseau de neurones à convolution profond ayant la même architecture que le VGG-GAP, ce qui lui a permis d'obtenir une augmentation de 0.04 de l'aire en dessous de la courbe (AED-CCR) sur la base de validation par rapport à la base d'origine. Une autre approche vise à incorporer les informations cliniques des patients dans l'apprentissage du modèle, c'est le cas des travaux de Hagerty[40].

Dans ce chapitre nous avons brièvement décrit le cancer du mélanome ainsi que l'approche clinique de son diagnostic. Nous avons également fait un état de l'art des méthodologies récentes employées pour la construction des systèmes de DAO des cancers de la peau.

Chapitre II : Méthodes

L'objectif d'un DAO du mélanome est de reproduire la démarche du dermatologue afin de différencier les natures des lésions en se basant sur un certain nombre de caractéristiques ou fonctionnalités. Dans ce chapitre, nous présenterons les DAO que nous avons développés durant notre étude ainsi que les deux approches abordées : approche classique et approche par apprentissage profond. Une description de la base de données utilisée et des critères d'évaluation de la performance des classifieurs sera également exposée.

II.1 La base de données et les critères de performances du modèle

II.1.1 La base de données

La base de données utilisée dans cette étude provient du programme de recherche SKINAN de l'Agence Nationale de Recherche. Le projet SKINAN consiste à construire un prototype spécialisé à l'analyse des images numériques de nævi via un algorithme d'apprentissage basé sur du machine learning et d'évaluer son apport pour le diagnostic de mélanome en routine clinique[41]. Les images constituant cette base sont des photographies dermoscopiques prises dans des conditions relativement standardisées et pour lesquelles le grossissement (nombre de pixels par centimètre de peau) est connue[42]. La base d'image SKINAN comporte 1356 images réparties en 9 classes telles que présentées par le *tableau 1* ci-dessous. Dans cette répartition, 2 classes (Mélanome et EOA Basocellulaire) représentent des lésions malignes. Lors de la construction par la suite de nos modèles de classifieurs, nous avons restructuré cette base en deux classes : une classe maligne et une classe bénigne. Afin d'évaluer la performance de notre modèle, nous avons également réparti la nouvelle base d'images ainsi formée en prenant 80% des deux classes ainsi formées pour le jeu d'entraînement et le reste pour le jeu de test.

Tableau 1 : Répartition par classe de la base de données SKINAN

Angiome	EOA Basocellulaire	Histiocytofribrome	Kératose Séborrhéique	Lentigo	Mélanome	Nævus	Nævus dysplasique	Nævus Naevo- cellulaire
44	68	46	312	85	105	238	286	172

Les images de la base SKINAN sont dans le format de couleur RVB avec différentes dimensions. Quelques exemples annotés d'images contenues dans la base sont présentés sur la *figure 3*.




Figure3 : Illustration des images présentes dans la base SKINAN (a) Naevus, (b) EOA Basocellulaire, (c) Mélanome

II.1.2 Evaluation de la performance du DAO

Il existe dans la littérature [26] plusieurs critères d'évaluation de la performance d'un système de diagnostic automatique. Dans le cadre de notre projet, nous nous servirons de trois d'entre elles qui s'avèrent être les plus pertinentes du point de vue du dermatologue: la sensibilité, la spécificité et l'aire en dessous de la courbe caractéristique du récepteur (AED - CCR).

- ❖ La sensibilité (SE) : C'est la capacité du modèle à identifier correctement les lésions malignes (taux de vrai positif). Sa formule est donnée par l'équation (1).

$$SE = \frac{VP}{VP+FN} \quad (1)$$

- ❖ La spécificité : C'est la capacité du modèle à identifier correctement les lésions bénignes (taux de vrai négatif). Sa formule est donnée par l'équation (2).

$$SP = \frac{VN}{VN+FP} \quad (2)$$

- ❖ AED -CCR : L'aire en dessous de la courbe caractéristique du récepteur correspond à la probabilité que le classifieur classe un exemple positif choisi au hasard plus élevé qu'un exemple négatif choisi au hasard. Il s'agit en réalité d'une comparaison entre les vrais positifs et les faux positifs.

II.2 Approche classique

L'approche classique que nous avons implémentée pour la classification des lésions se subdivise en trois principales parties : le prétraitement, l'extraction de fonctionnalités et la classification.

II.2.1 Le prétraitement

Nous avons choisi de réduire au minimum les étapes de prétraitement afin de permettre aux modèles de facilement se généraliser à d'autres bases. Ainsi, pour cette approche nous n'appliquerons que deux étapes de prétraitement. Premièrement les images sont redimensionnées à la même taille 800*600 en utilisant une interpolation bicubique. Ensuite, elles sont normalisées avec la méthode *normalize* de la librairie Scikit-learn qui centre les données à moins d'une unité de l'origine.

II.2.2 Extraction de fonctionnalités

Pour cette approche, trois types d'extracteurs sont utilisés : Le motif binaire local (MBL), la couleur et l'histogramme des gradients (HOG). Le choix des extracteurs est primordial car les fonctionnalités qui en seront extraites influent directement sur les performances du classifieur. 7680 fonctionnalités sont ainsi extraites. Ces fonctionnalités sont réparties de la manière suivante : 7080 pour le MBL, 60 pour la couleur et 540 pour le HOG.

➤ **MBL**

Le motif binaire local est un extracteur de la texture d'une image. Son principe général est de comparer le niveau de luminosité d'un pixel avec les niveaux de ses voisins. La texture d'une image peut être définie comme étant l'organisation spatiale de l'intensité et de la couleur d'une image. Nous nous sommes inspirés des travaux de WAZAEFI [43] pour extraire des histogrammes MBL des images.

➤ **Couleur**

La couleur de la lésion est une information importante lors du diagnostic d'une lésion par le dermatologue. Nasir[19] l'a décrite comme étant l'une des plus importante pour la construction de DAO. Ainsi des caractéristiques de couleur telles que la variance et la moyenne calculées sur des images RVB sont régulièrement utilisées pour la construction des DAO[44]. Néanmoins, la grande variabilité des conditions d'acquisition des images a poussé les scientifiques à utiliser différents espaces de représentation de couleur pour réduire le risque de forte corrélation entre les paramètres calculés. Nous avons utilisé pour cet extracteur 4 espaces de couleurs (RVB, LAB, TSC et YCbCr) pour extraire 5 caractéristiques de couleurs : l'entropie, l'asymétrie, la moyenne, l'écart type et l'acuité de la distribution des pixels pour chaque composante couleur.

➤ **HOG**

L'HOG est l'un des extracteurs les plus utilisés pour la reconnaissance de forme. En se référant à la règle ABCDE et à la méthode des 7 points de la liste de contrôle présentées dans la section I.1, il en ressort que la forme de la lésion est une caractéristique essentielle pour la classification de la lésion. Nous avons utilisé un extracteur ayant une taille de cellule assez grande (125*125) afin de récupérer la forme globale de chaque lésion.

II.2.3 Classification

Notre approche classique de construction de DAO utilise le principe de classification supervisée. Nous avons au préalable partitionné les fonctionnalités extraites précédemment en deux vecteurs de fonctionnalités : mélanome contre bénin et basocellulaire contre bénin. Chacun de ces vecteurs est utilisé pour entraîner deux modèles de machines à vecteurs de support (MVS). Nous avons entraîné les modèles avec une fonction de coût linéaire de type L2 grâce à la librairie LIBLINEAR(C=0.1)[45]. La *figure 4* présente le système de DAO que nous avons proposé.

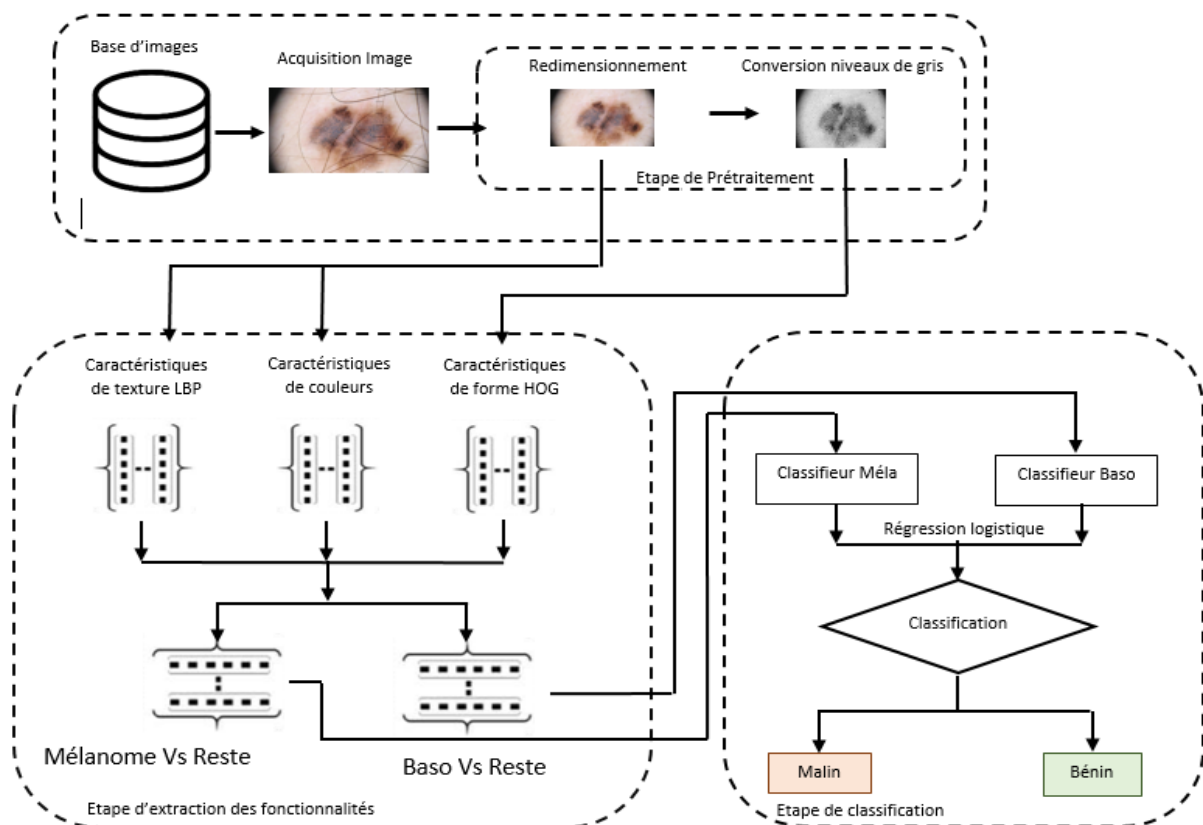


Figure 4: architecture de l'approche classique du système de DAO proposé

II.3 Approche par apprentissage profond

L'approche par apprentissage profond que nous avons implémentée pour la classification des lésions se subdivise en quatre principales parties : le prétraitement, le pré-entraînement, l'extraction de fonctionnalités et la classification. Elle diffère de l'approche classique en ce sens qu'elle repose sur des techniques d'apprentissage profond en intelligence artificielle. De la même manière et pour les mêmes raisons que l'approche classique présentée précédemment, le prétraitement est réduit à deux étapes. Les images sont préalablement redimensionnées à la taille 224*224 ensuite, elles sont normalisées en soustrayant le nombre de pixel moyen de la base ImageNet, ceci parce que les modèles profonds utilisés ont été entraînés sur cette base.

II.3.1 Pré-entraînement et extraction de fonctionnalités

Du fait du nombre limité d'images que nous avons à notre possession, nous avons choisi de développer notre algorithme en nous basant sur des modèles profonds pré-entraînés en l'occurrence ResNet50[30] et VGG16[29]. Nous avons dans un premier temps légèrement modifié l'architecture des modèles pré-entraînés en remplaçant leurs dernières couches (*fc1000* pour resnet50 et *predictions* pour VGG16) par des réseaux complètement connectés (CC). Les *tableaux 2* et *3* ci-dessous décrivent l'architecture des couches ajoutées sur chaque modèle. Durant la phase d'apprentissage, seuls les poids des couches ajoutées sont mis à jour en utilisant l'algorithme d'optimisation RMSprop ($lr=0.001$, $\rho=0.9$). L'extraction des fonctionnalités est ensuite faite sur la couche *avg_pool* (2048 fonctionnalités) du modèle resnet50 et sur les couches *Dense_8* (256 fonctionnalités) et *Dense_10* (64 fonctionnalités).

Tableau 2 : Paramètres des couches ajoutées au modèle VGG16

Nom Couche (Type)	Taille	Paramètres
Dense_8 (CC)	256	Activation : Relu
Dropout_4 (Dropout)	256	
Dense_9 (CC)	128	Activation : Relu
Dropout_5 (Dropout)	128	
Dense_10 (CC)	64	Activation : Relu
Dropout_6 (Dropout)	64	
Dense_11 (CC)	1	Activation: Sigmoid

Tableau 3 : Paramètres des couches ajoutées au modèle resnet50

Nom Couche (Type)	Taille	Paramètres
CC	1	Activation : Sigmoid

II.3.2 Classification

Les fonctionnalités extraites dans les étapes précédentes sont utilisées pour entrainer deux modèles linéaires MVS pour effectuer la classification des lésions. La probabilité d'appartenance à une classe ou à une autre est par la suite générée par un algorithme de régression logistique. La *figure 5* présente l'architecture de l'approche par apprentissage profond proposée.

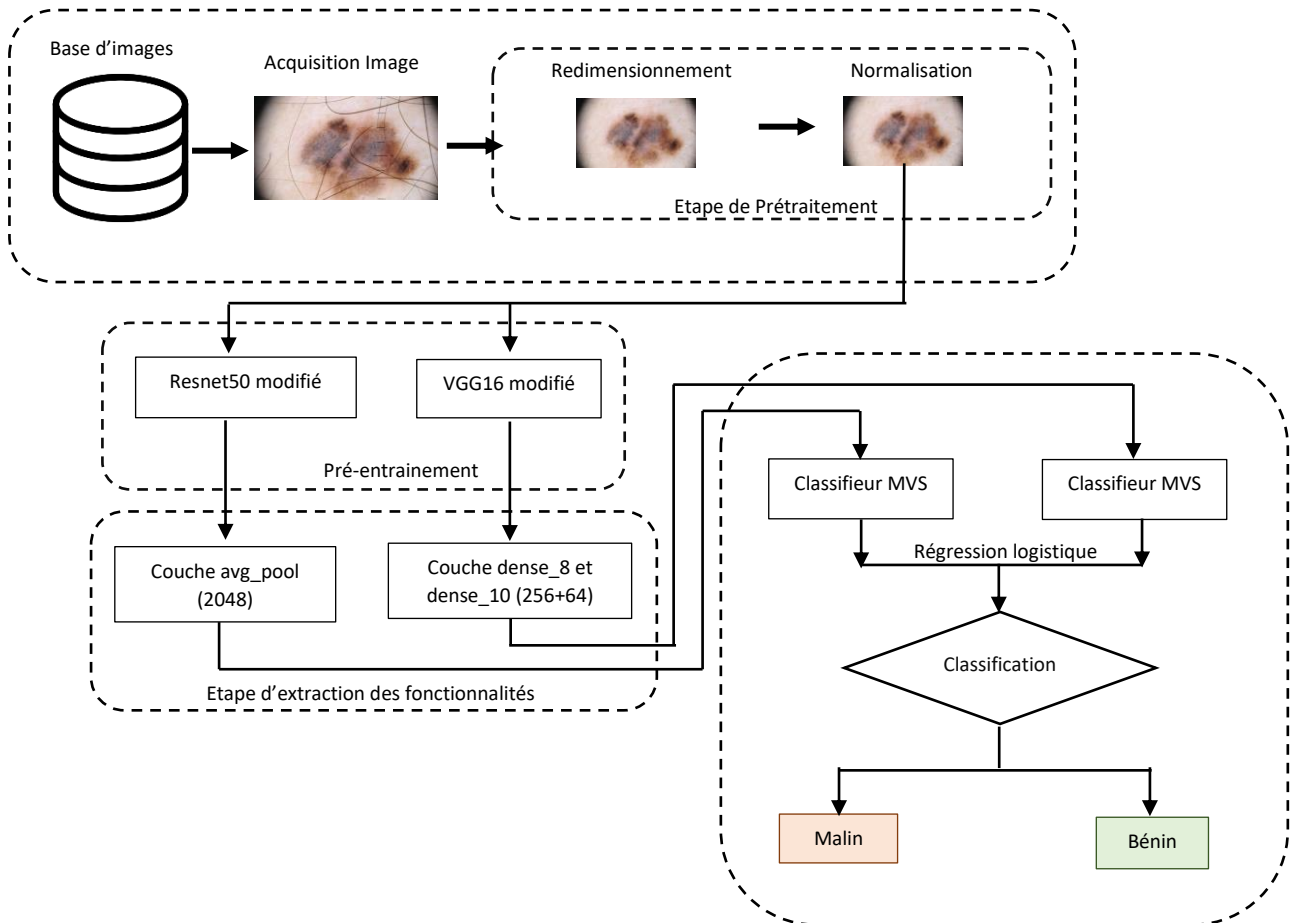


Figure 5 : architecture de l'approche par apprentissage profond du système de DAO proposé

II.4 Outils et matériels

Dans notre étude, nous avons utilisé les environnements de programmation Python à travers la distribution anaconda et Matlab ceci à cause de la flexibilité et du nombre conséquent de ressources disponibles à leur sujet. Nous avons utilisé la librairie Scikit-learn[46] pour l'implémentation de l'algorithme de classification MVS et Matlab pour l'extraction des fonctionnalités décrites dans la section II.2. La librairie pour python Keras[47] nous a servi pour l'implémentation des architectures des réseaux profonds présentées dans la section II.3. A tout cela, s'ajoute la librairie CUDA[48] indispensable pour faire fonctionner la carte graphique Nvidia GEFORCE RTX 2070 qui a été mise à notre disposition pour nos implémentations.

Chapitre III : Résultats et discussion

Ce chapitre présente les résultats obtenus à la suite de l'implémentation des méthodes proposées. Comme mentionné précédemment, nous avons réparti notre base en prenant 80% de celle-ci pour constituer le jeu d'entraînement, mais aussi comme jeu de validation en utilisant le principe de la validation croisée (Avec 20 rangés). Ceci afin d'obtenir une évaluation la plus globalisante possible de nos modèles. Le modèle après validation est ensuite appliqué sur le jeu de test.

III.1 Approche classique

Nous avons dans un premier temps examiné l'influence de chaque extracteur en utilisant de façon individuelle les fonctionnalités extraites de chacune d'elle pour entraîner un MVS. Le *tableau 4* présente les résultats de cette observation. L'extracteur MBL est celui qui a présenté les meilleures performances après une validation croisée à 20 rangés sur le jeu d'entraînement. Par la suite, la combinaison des trois extracteurs a amélioré la performance du classifieur, notamment sa spécificité et sa précision. Le *Tableau 5* et la *figure 6* présentent la performance de la combinaison des trois extracteurs sur le jeu de test.

Tableau 4 : Validation croisée sur le jeu d'entraînement de chaque extracteur

Extracteur	Sensibilité	Spécificité	AED-CCR
MBL	74%±0.1	82%±0.1	0.88 ± 0.1
Couleur	49%±0.2	81%±0.03	0.78±0.1
HOG	59%±0.2	80%±0.03	0.76 ± 0.1
MBL+Couleur+HOG	74%±0.2	87%±0.1	0.88 ± 0.1

Tableau 5 : Evaluation sur le jeu de test de la combinaison des trois extracteurs

	Prédit Malin	Prédit Bénin	SE	SPEC	AED-CCR
Malin	26	11	70%	85%	0.85
Bénin	36	199			




Figure 6 : courbe CCR de la combinaison des trois extracteurs sur le jeu de test

Dans un deuxième temps, nous avons évalué comment se comportaient les 3 extracteurs sur une classification de type Basocellulaire contre bénin (*BasoVsReste*) et Mélanome contre bénin (*MelaVsReste*). On constate à partir du *tableau 6*, que les 3 extracteurs parviennent plus aisément à décrire les lésions mélanocytaires par rapport aux lésions bénignes, tandis que les basocellulaires quant à eux ont un peu plus de mal à se faire identifier. Les *Tableaux 7* et *8* présentent respectivement la performance sur le jeu de test du classifieur *BasoVsReste* et *MelaVsReste*.

Tableau 6 : Validation croisée sur le jeu d'entraînement des classifieurs *BasoVsReste* et *MelaVsReste*

Classifieur	Sensibilité	Spécificité	AED-CCR
BasoVsReste	56%±0.3	84%±0.04	0.79 ± 0.1
MélaVsRest	82%±0.1	85%±0.05	0.92±0.1

Tableau 7 : Evaluation sur le jeu de test du classifieur *BasoVsReste*

	Prédit Malin	Prédit Bénin	SE	SPEC	AED-CCR
Malin	10	3	77%	81%	0.84
Bénin	45	193			

Tableau 8 : Evaluation sur le jeu de test du classifieur *MelaVsReste*

	Prédit Malin	Prédit Bénin	SE	SPEC	AED-CCR
Malin	18	2	90%	86%	0.95
Bénin	33	205			

Les bonnes performances obtenues par les deux classifieurs *BasoVsReste* et *MelaVsReste* sur le jeu de test nous ont conduits à développer notre modèle d'approche classique décrite à la **section II.2.3**. Le *tableau 9* et la *figure 7* présentent la performance de ce modèle sur le jeu de test de départ. On constate une nette amélioration de la sensibilité et de l'AED-CCR du classifieur respectivement de 70% à 89% et de 0.85 à 0.88. Néanmoins, cela a pour conséquence de faire chuter la spécificité de 85% à 77%.

Tableau 9 : Evaluation sur le jeu de test de notre modèle d'approche classique

	Prédit Malin	Prédit Bénin	SE	SPEC	AED-CCR
Malin	33	4	89%	77%	0.88
Bénin	54	181			

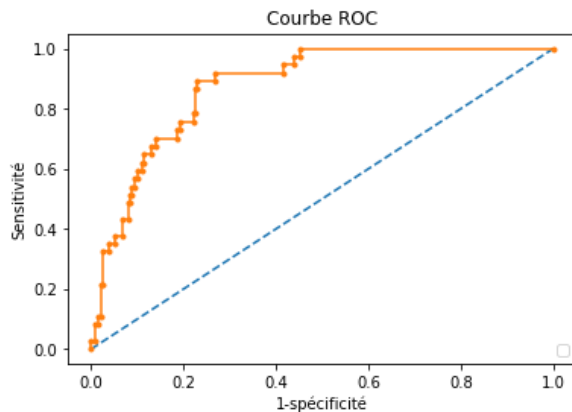


Figure 7 : courbe CCR de notre modèle d'approche classique sur le jeu de test

Dans le cadre de notre modèle classique, nous nous sommes enfin intéressés au comportement du modèle à une échelle multi classe. La *figure 8* représente la sensibilité du modèle pour chacune des 9 classes présentes sur le jeu de test en fonction du seuil. On remarque que le modèle comme décrit précédemment distingue plus aisément les mélanomes que les basocellulaires. De même, le modèle performe assez bien avec toutes les classes à l'exception des angiomes donc la courbe se situe en dessous de la ligne diagonale traduisant le caractère hasardeux ou non d'une classification. La classe kératose également se situe à la limite.




Figure8 : Sensibilité du modèle classique par rapport aux 9 classes

III.2 Approche par apprentissage profond

Comme précisé précédemment, le nombre réduit d'images de notre base de données nous a conduit à adopter une approche de transfert d'apprentissage pour notre modèle par apprentissage profond. Les jeux d'entraînement et de test utilisés ici sont les mêmes que ceux utilisés dans l'approche classique pour des raisons de comparabilité. Le *tableau 10* présente les résultats obtenus après validation croisée sur la base d'entraînement par les deux modèles Resnet50 et VGG16 modifiés que nous avons utilisés. Il en résulte que les deux modèles ont des performances relativement similaires. Les *tableaux 11* et *12* présentent les performances de ces deux modèles sur le jeu de test.

Tableau 10 : Validation croisée sur le jeu d'entraînement des modèles pré-entraînés modifiés

Classifieur	Sensibilité	Spécificité	AED-CCR
Resnet50 modifié	72%±0.2	85%±0.1	0.86 ± 0.1
VGG16 modifié	74%±0.2	79%±0.1	0.87±0.1

Tableau 11 : Evaluation sur le jeu de test du modèle resnet50 modifié

	Prédit Malin	Prédit Bénin	SE	SPEC	AED-CCR
Malin	27	10	73%	86%	0.87
Bénin	33	202			

Tableau 12 : Evaluation sur le jeu de test du modèle vgg16 modifié

	Prédit Malin	Prédit Bénin	SE	SPEC	AED-CCR
Malin	29	8	78%	79%	0.88
Bénin	49	186			

Par la suite, nous avons combiné les deux modèles pré-entraînés en entraînant un algorithme de régression logistique. Le *tableau 13* et la *figure 9* présentent les performances de cette nouvelle configuration sur le jeu de test. Ceci a eu pour conséquence d'améliorer la spécificité du modèle.

Tableau 13 : Evaluation sur le jeu de test combinaison

	Prédit Malin	Prédit Bénin	SE	SPEC	AED-CCR
Malin	29	8	78%	83%	0.88
Bénin	40	195			




Figure 9 : courbe CCR de notre modèle d'approche par apprentissage profond sur le jeu de test

La figure 10 représente la sensibilité du modèle pour chacune des 9 classes présentes sur le jeu de test en fonction du seuil. On remarque comme le modèle classique, que les mélanomes sont plus aisément distingués que les basocellulaires. Les angiomes sont toujours aussi mal classés, par contre, on remarque que les naevus naevo-cellulaire sont facilement distingués par le modèle.




Figure10 : Sensibilité du modèle par apprentissage profond par rapport aux 9 classes

Conclusion et recommandation

Dans ce travail, le problème du diagnostic du mélanome a été abordé par le développement de système de diagnostic assisté par ordinateur. L'objectif était de construire de manière supervisée des descripteurs pertinents en vue d'établir des matrices de similitude entre lésions mélanocytaires. Ceci afin d'élaborer un classifieur pertinent pour la reconnaissance des lésions mélanocytaires. Les performances obtenues par les modèles développés nous ont donnés des résultats satisfaisants. Notre principale contribution a été le développement de deux classifieurs spécialisés (MelaVsReste et BasoVsReste) et la combinaison de leurs probabilités afin d'améliorer la performance du classifieur final ceci avec un minimum de prétraitement sur la base. Cela nous a permis de démontrer que pour des problèmes de classification binaire, la combinaison de modèles ayant été entraînés à classifier des classes distinctes conduit à l'amélioration de la performance globale de la classification une fois appliquée sur une base comportant toutes les classes. Les éventuelles suites à donner à ce travail sont d'agrandir la base de données utilisée pour l'implémentation, notamment avec les bases de données publiques telles que ISIC. D'explorer les techniques visant à pallier au problème récurrent de déséquilibre des bases de données. L'approche par apprentissage profond, malgré le nombre limité de données à notre possession, a donné des résultats comparables à l'approche classique, il sera également intéressant d'approfondir notre étude sur les propriétés des fonctions de coût utilisées par ces modèles, et ainsi étudier l'influence des différents paramètres de ces fonctions sur le résultat de classification.

Bibliographie

1. Gaudy-Marqueste, C., et al., *Ugly duckling sign as a major factor of efficiency in melanoma detection*. JAMA dermatology, 2017. **153**(4): p. 279-284.
2. Esteva, A., et al., *Dermatologist-level classification of skin cancer with deep neural networks*. Nature, 2017. **542**(7639): p. 115.
3. *Les cancers en France*. 2017, Collection Les Données. p. 254.
4. Longvert, C. and P. Saiag, *Actualités dans le mélanome cutané*. La revue de médecine interne, 2019. **40**(3): p. 178-183.
5. Stolz, w., A. Riemann, and A.B. Cagnetta, *ABCD rule of dermoscopy: A new practical method for early recognition of malignant melanoma*. European journal of dermatology, 1994. **4**(7): p. 521-527.
6. Capdehourat, G., et al., *Toward a combined tool to assist dermatologists in melanoma detection from dermoscopic images of pigmented skin lesions*. Pattern recognition letters, 2011. **32**(16): p. 2187-2196.
7. Lorentzen, H., K. Weismann, and L. Secher, *The dermoscopic ABCD rule does not improve diagnostic accuracy of malignant melanoma*. Acta Dermato-venereologica, 1999. **79**(6): p. 469-472.
8. Jhr, R., *Dermoscopy: alternative melanocytic algorithms-the ABCD rule of dermoscopy, menzies scoring method, and 7-point checklist*. Clinics in dermatology, 2002. **20**(3): p. 240-247.
9. Lee, T., et al., *Dullrazor®: A software approach to hair removal from images*. Computers in biology and medicine, 1997. **27**(6): p. 533-543.
10. Celebi, M.E., et al., *A methodological approach to the classification of dermoscopy images*. Computerized Medical imaging and graphics, 2007. **31**(6): p. 362-373.
11. Barata, C., J.S. Marques, and J. Rozeira, *A system for the detection of pigment network in dermoscopy images using directional filters*. IEEE transactions on biomedical engineering, 2012. **59**(10): p. 2744-2754.
12. Marques, J.S., C. Barata, and T. Mendonça. *On the role of texture and color in the classification of dermoscopy images*. in *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. 2012. IEEE.
13. Bisla, D., et al., *Skin Lesion Segmentation and Classification with Deep Learning System*. arXiv preprint arXiv:1902.06061, 2019.
14. RONNEBERGER, O., FISCHER, Philipp, et BROX, Thomas, *U-net: Convolutional networks for biomedical image segmentation*, in *International Conference on Medical image computing and computer-assisted intervention*. 2015, Springer, Cham. p. 234-241.
15. Sood, H. and M. Shukla, *Various Techniques for Detecting Skin Lesion: A Review*. International Journal of Computer Science and Mobile Computing, 2014. **3**(5): p. 905-912.
16. Silveira, M., et al., *Comparison of segmentation methods for melanoma diagnosis in dermoscopy images*. IEEE Journal of Selected Topics in Signal Processing, 2009. **3**(1): p. 35-45.
17. Adeyinka, A.A. and S. Viriri. *Skin Lesion Images Segmentation: A Survey of the State-of-the-Art*. in *International Conference on Mining Intelligence and Knowledge Exploration*. 2018. Springer.
18. Chang, W.-Y., et al., *The feasibility of using manual segmentation in a multifeature computer-aided diagnosis system for classification of skin lesions: a retrospective comparative study*. BMJ open, 2015. **5**(4): p. e007823.
19. Nasir, M., et al., *An improved strategy for skin lesion detection and classification using uniform segmentation and feature selection based approach*. Microscopy research and technique, 2018. **81**(6): p. 528-543.
20. Oliveira, R.B., et al., *Computational methods for pigmented skin lesion classification in images: review and future trends*. Neural Computing and Applications, 2018. **29**(3): p. 613-636.
21. Okuboyejo, D.A. and O.O. Olugbara, *A review of prevalent methods for automatic skin lesion diagnosis*. The Open Dermatology Journal, 2018. **12**(1).

22. Mishra, N.K. and M.E. Celebi, *An overview of melanoma detection in dermoscopy images using image processing and machine learning*. arXiv preprint arXiv:1601.07843, 2016.
23. Maglogiannis, I. and C.N. Doukas, *Overview of advanced computer vision systems for skin lesions characterization*. IEEE transactions on information technology in biomedicine, 2009. **13**(5): p. 721-733.
24. Pathan, S., K.G. Prabhu, and P. Siddalingaswamy, *Techniques and algorithms for computer aided diagnosis of pigmented skin lesions—A review*. Biomedical Signal Processing and Control, 2018. **39**: p. 237-262.
25. Brinker, T.J., et al., *Skin cancer classification using convolutional neural networks: systematic review*. Journal of medical Internet research, 2018. **20**(10): p. e11936.
26. Sultana, N.N. and N. Puhan. *Recent Deep Learning Methods for Melanoma Detection: A Review*. in *International Conference on Mathematics and Computing*. 2018. Springer.
27. Mahbod, A., et al. *Skin lesion classification using hybrid deep neural networks*. in *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2019. IEEE.
28. Krizhevsky, A., I. Sutskever, and G.E. Hinton. *Imagenet classification with deep convolutional neural networks*. in *Advances in neural information processing systems*. 2012.
29. Simonyan, K. and A. Zisserman, *Very deep convolutional networks for large-scale image recognition*. arXiv preprint arXiv:1409.1556, 2014.
30. He, K., et al. *Deep residual learning for image recognition*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
31. Szegedy, C., et al. *Rethinking the inception architecture for computer vision*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
32. Lopez, A.R., et al. *Skin lesion classification from dermoscopic images using deep learning techniques*. in *2017 13th IASTED International Conference on Biomedical Engineering (BioMed)*. 2017. IEEE.
33. Kawahara, J. and G. Hamarneh. *Multi-resolution-tract CNN with hybrid pretrained and skin-lesion trained layers*. in *International Workshop on Machine Learning in Medical Imaging*. 2016. Springer.
34. Kawahara, J., A. BenTaieb, and G. Hamarneh. *Deep features to classify skin lesions*. in *2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI)*. 2016. IEEE.
35. Zhang, X., et al., *Towards improving diagnosis of skin diseases by combining deep neural network and human knowledge*. BMC Medical Informatics and Decision Making, 2018. **18**(2): p. 59.
36. Radford, A., L. Metz, and S. Chintala *Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks*. arXiv e-prints, 2015.
37. Barata, C., M.E. Celebi, and J.S. Marques, *Improving dermoscopy image classification using color constancy*. IEEE journal of biomedical and health informatics, 2015. **19**(3): p. 1146-1152.
38. Zhou, B., et al. *Learning deep features for discriminative localization*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
39. Jia, X. and L. Shen, *Skin lesion classification using class activation map*. arXiv preprint arXiv:1703.01053, 2017.
40. Hagerty, J., et al., *Deep Learning and Handcrafted Method Fusion: Higher Diagnostic Accuracy for Melanoma Dermoscopy Images*. IEEE Journal of Biomedical and Health Informatics, 2019: p. 1-1.
41. Recherche, A.N.d.I. *SKIN ANalyzer : diagnostic du mélanome assisté par ordinateur – Skinan*. 2002 30 avril 2019]; Available from: <https://anr.fr/Projet-ANR-07-EMPB-0031>.
42. Medical, A. *Technologie*. 06 mai 2019]; Available from: <https://anapix-medical.com/dermatologues-diagnostic-assiste-par-ordinateur/?lang=fr>.
43. Wazaefi, Y., S. Paris, and B. Fertil. *Contribution of a classifier of skin lesions to the dermatologist's decision*. in *2012 3rd International Conference on Image Processing Theory, Tools and Applications (IPTA)*. 2012. IEEE.
44. Ganster, H., et al., *Automated melanoma recognition*. IEEE transactions on medical imaging, 2001. **20**(3): p. 233-239.

45. Fan, R.-E., et al., *LIBLINEAR: A library for large linear classification*. Journal of machine learning research, 2008. **9**(Aug): p. 1871-1874.
46. Pedregosa, F., et al., *Scikit-learn: Machine learning in Python*. Journal of machine learning research, 2011. **12**(Oct): p. 2825-2830.
47. Chollet, F., *Keras*. 2015.
48. Sanders, J. and E. Kandrot, *CUDA by example: an introduction to general-purpose GPU programming*. 2010: Addison-Wesley Professional.