



Département de Génie Électrique et Informatique Industrielle
Projet de Fin d'Études pour l'Obtention du Diplôme d'Ingénieur

- Spécialité -
Systèmes et Réseaux de Télécommunication

- Sujet -
Conception d'un système à faible coût pour la détection et
la classification des anomalies cutanées à l'aide
de techniques d'apprentissage profond

Réalisé par :

BADAoui Aymen
BIBET Idris

Membres du jury :

Nom	Établissement	Grade	Qualité
Mme BOUTERFAS Ma- lika	ENSTA	M.C.A	Président du jury
Mme HABANI Lamia-	ENSTA	M.A.A	Examineur
M ABBADI Belkacem	ENSTA	M.C.B	Examineur
Mme Kheira LAKHDARI	ENSTA	M.A.B	Co-encadrante
Mme Ferrahi Ibtissem	USTHB	M.C.B	Encadrante

Dédicaces

Badaoui Aymen

À ceux qui ont rendu ce parcours possible par leur aide précieuse

Bibet Idriss

Je dédie ce modeste travail à tous ceux et celles qui m'ont aidé de près ou de loin, notamment : À mes chers parents, qui ne m'ont jamais laissé tomber, quelles que soient les circonstances.

À mon frère et à ma sœur que j'aime profondément.

À tous mes enseignants qui ont contribué à ma formation.

À tous mes amis qui m'ont toujours soutenu.

À toute la famille **BIBET**.

Remerciements

Nous tenons à remercier sincèrement les membres du jury qui nous font l'honneur d'évaluer ce projet. Leur disponibilité et leur intérêt pour notre travail représentent pour nous un réel encouragement.

Nous exprimons notre reconnaissance la plus sincère à nos encadrantes, Madame Ferrahi Ibtissem et Madame Lakhdari Kheira, pour leur accompagnement attentif, leurs conseils éclairés et leur soutien constant tout au long de ce projet. Leur expertise, leur bienveillance et leur disponibilité ont été essentielles à la réussite de ce travail.

Nos remerciements vont également à l'ensemble de l'équipe pédagogique de l'École Nationale Supérieure de Télécommunications (ENSTA) pour la qualité de la formation reçue durant notre parcours académique.

Abstract

This project belongs to the field of artificial intelligence applied to health-care, specifically computer-aided skin cancer detection from dermatological images. The main goal was to design a complete, intelligent, and autonomous system capable of detecting, localizing, and classifying skin lesions using deep learning techniques.

To achieve this, the ISIC 2019 dataset was used to train two complementary models: a binary classification model (benign vs malignant lesions) and a multi-class classification model (melanoma, BCC, NV, etc.). The results are promising, with an AUC of 94.91% for binary classification and 99.41% for multi-class classification.

In parallel, a YOLOv8 Nano detection model was integrated to automatically locate the lesion region from raw images, enabling targeted extraction of regions of interest. These models were embedded in a desktop application linked to a Raspberry Pi, and a mobile version optimized with TensorFlow Lite was also developed for smartphone-based diagnosis.

This solution aims to provide an accessible, standalone, and reliable tool for early melanoma detection, especially in resource-constrained medical environments. Future directions include clinical validation, integration of fine lesion segmentation, and longitudinal lesion tracking. **Keywords:**

Artificial Intelligence, Skin Cancer, YOLOv8, Classification, ISIC 2019, Computer-Aided Diagnosis.

Résumé

Ce travail s'inscrit dans le domaine de l'intelligence artificielle appliquée à la santé, plus précisément dans la détection assistée par ordinateur du cancer de la peau à partir d'images dermatologiques. L'objectif principal était de concevoir un système complet, intelligent et autonome permettant de détecter, localiser et classifier des lésions cutanées à l'aide de techniques d'apprentissage profond.

Pour cela, le dataset ISIC 2019 a été utilisé pour entraîner deux modèles complémentaires : un modèle de classification binaire (lésions bénignes vs malignes), et un modèle de classification multi-classes (Mélanome, BCC, NV, etc.). Les performances obtenues sont très encourageantes, avec une AUC atteignant 94.91% pour la classification binaire et 99.41% pour la classification multi-classes.

Parallèlement, un modèle YOLOv8 Nano a été intégré pour localiser automatiquement la zone de la lésion à partir d'images brutes, facilitant l'extraction ciblée des régions d'intérêt. Ces modèles ont été intégrés dans une application desktop reliée à une carte Raspberry Pi, ainsi qu'une version mobile optimisée avec TensorFlow Lite pour un diagnostic sur smartphone.

Cette solution vise à offrir un outil accessible, autonome et fiable pour la détection précoce du mélanome, notamment dans les environnements médicaux à ressources limitées. Les perspectives incluent une validation clinique, l'intégration de la segmentation fine, et le suivi longitudinal des lésions. **Mots-clés** : Intelligence artificielle, cancer de la peau, YOLOv8, classification, ISIC 2019, diagnostic automatique.

الملخص

يندرج هذا العمل ضمن مجال الذكاء الاصطناعي المطبق في الصحة، وتحديدًا في الكشف الآلي عن سرطان الجلد باستخدام صور الأمراض الجلدية. الهدف الرئيسي من هذا المشروع هو تصميم نظام ذكي ومتكامل وقادر على العمل بشكل ذاتي من أجل الكشف، تحديد الموضع، وتصنيف الآفات الجلدية باستخدام تقنيات التعلم العميق.

تم استخدام قاعدة بيانات ISIC 2019 لتدريب نموذجين مكملين: نموذج تصنيف ثنائي (الآفات الغير خبيثة مقابل الخبيثة) ونموذج تصنيف متعدد الفئات (مثل الميلانوما، سرطان الخلايا القاعدية، إلخ). وقد أظهرت النتائج أداءً متميزًا مع AUC بلغ ٩١.٩٤% للتصنيف الثنائي و١٤.٩٩% للتصنيف المتعدد.

بالإضافة إلى ذلك، تم دمج نموذج YOLOv8 Nano لاكتشاف موقع الآفة تلقائيًا من الصور الخام، مما يسهل استخراج المناطق المهمة. وتم دمج هذه النماذج في تطبيق مكتبي مرتبط بجهاز Raspberry Pi، كما تم تطوير إصدار محمول باستخدام TensorFlow لتوفير التشخيص عبر الهاتف الذكي.

يهدف هذا النظام إلى تقديم أداة فعالة، موثوقة وسهلة الاستخدام للكشف المبكر عن سرطان الجلد، خصوصًا في المناطق ذات الموارد المحدودة. وتشمل آفاق التطوير مستقبلاً: التحقق السريري، إدماج نماذج تقسيم دقيقة، وتتبع تطور الآفات عبر الزمن.

الكلمات المفتاحية: ذكاء الاصطناعي سرطان الجلد، YOLOv8 ، التصنيف، ISIC 2019 ، التشخيص الآلي.

Table des matières

Introduction	2
1 Chapitre 1 : Lésion de peau et technologies	4
1.1 Introduction	4
1.2 Lésions cutanées : Typologie et enjeux médicaux	4
1.2.1 Peau	4
1.2.2 Lésions cutanées	5
1.2.3 Tumeurs cutanées	5
1.2.4 Mélanome cutané	6
1.2.5 Carcinomes cutanés	6
1.2.6 Formes rares : Carcinome à cellules de Merkel	7
1.3 Contraintes et problématiques médicales	8
1.4 Avancées technologiques dans la dermatologie	8
1.4.1 Médecine personnalisée et médecine régénérative	8
1.4.2 Télémédecine et suivi à distance	9
1.4.3 Imagerie avancée	9
1.4.4 Nanotechnologie	10
1.4.5 Intelligence Artificielle et apprentissage automatique	11
1.5 Évolution de l'intelligence artificielle en dermatologie	11
1.5.1 Premières avancées (2010–2017) : Démonstration de faisabilité . . .	13
1.5.2 Expansion et validation (2018–2020) : comparaisons homme–machine	13
1.5.3 Applications cliniques (2021–2023) : collaboration IA–médecins . .	13
1.5.4 Défis persistants et orientations futures	13
1.5.5 Tendances futures (2024 et au-delà)	14
1.5.6 Apports de l'IA dans la prise en charge dermatologique : perspec- tives patients et praticiens	14
1.6 Conclusion	15
2 Chapitre 2 : Système Proposé et Choix de technologies	16
2.1 Introduction	16
2.2 Présentation du système <i>DermAI-Detect</i>	16

2.3	Objectives fixé pour notre système	17
2.4	Choix de la base de données	17
2.5	Sélection de la Carte Embarquée pour le Système Ciblé	19
2.6	Choix des modèles	20
2.6.1	Premier choix exploré : Méthodes de traitement d'image classiques .	20
2.6.2	Deuxieme choix exploré Réseaux de Neurones Artificiels (ANN) . .	22
2.6.3	Troisieme choix exploré Réseaux auto-organisants de Kohonen (SOM)	22
2.6.4	Quatrieme choix exploré Réseaux de Neurones Convolutifs (CNN) .	22
2.7	Conclusion	26
3	Chapitre 3 :Solution,Conception et Déploiement du Système Proposé	27
3.1	Introduction	27
3.2	Architecture globale du système	27
3.3	Pipeline de traitement de données	28
3.3.1	Conversion de l'espace colorimétrique RGB vers HSV	29
3.3.2	Suppression de l'arrière-plan par seuillage dans l'espace HSV	29
3.3.3	Segmentation via seuillage d'Otsu	30
3.3.4	Post-traitement morphologique du masque de segmentation	30
3.3.5	Application finale du masque sur l'image filtrée	30
3.4	Module de classification	31
3.4.1	Architecture des modèles	32
3.4.2	Augmentation de Données	34
3.4.3	Compilation et réglages d'entraînement	38
3.5	Modèle de collecte automatisée de nouvelles données	40
3.5.1	Objectif et principe	40
3.5.2	Architecture du modèle	40
3.5.3	Etapas du développement	41
3.5.4	Avantages	41
3.6	Intégration des modèles dans deux systèmes applicatifs	41
3.6.1	Introduction	41
3.6.2	Architecture générale	41
3.6.3	Intégration dans le système Desktop avec Raspberry Pi	42
3.6.4	Intégration dans l'application mobile	48
3.7	Conclusion	51
4	Chapitre 4 :Résultats et Discussion	52
4.1	Introduction	52
4.2	Évaluation du modèle de classification binaire	52
4.3	Évaluation du modèle de classification multi-classes	56
4.4	Évaluation du modèle de détection	61

4.5	Discussion	64
4.5.1	Analyse des résultats	64
4.5.2	Forces et faiblesses du système	66
4.5.3	Axes d'amélioration	67
4.5.4	Synthèse de la discussion	67
4.6	Conclusion	67
Conclusion Générale et Perspectives		68

Table des figures

1.1	les trois couches de peau	5
1.2	Évolution du nombre de publications et des citations sur l'intelligence artificielle appliquée à la dermatologie cutanée entre 1991 et 2023. Source : [11].	12
3.1	Schéma global de l'architecture de <i>DermAI-Detect</i>	28
3.2	Images comparatives avant et après suppression du fond noir	29
3.3	Images comparatives avant et après segmentation otsu	30
3.4	Images comparatives avant et après application du masque finale	31
3.5	architecture du module de classification	31
3.6	Architecture commune utilisée pour la classification binaire et multiclasse .	33
3.7	architecture du module de classification	35
3.8	Résultat de l'algorithme Mixup sur deux images d'entrée	36
3.9	Résultat de l'algorithme CutMix sur deux images d'entrée	37
3.10	Schéma simplifié de l'architecture du systeme	42
3.11	image du montage réel	42
3.12	Schéma simplifié de l'architecture du systeme	43
3.13	Schéma simplifié de l'architecture logicielle de l'application Desktop	44
3.14	Captures d'écran de l'application	46
3.15	Captures d'écran montrant la détection en temps réel via l'application . . .	47
3.16	Schéma simplifié de l'architecture logicielle de l'application mobile	49
3.17	captures de l'application mobile	50
4.1	Évaluation des performances pour la classification binaire.	53
4.2	Exemples de résultats de détections sur des images externes	55
4.3	Visualisation des performances du modèle sur l'ensemble de test.	57
4.4	Captures de l'application mobile	60
4.5	résultat de l'entraînemen	62
4.6	Exemples de détections réalisées par le modèle YOLOv8 Nano	63

Liste des tableaux

2.1	Comparaison des méthodes pour la détection des lésions cutanées avec références	25
3.1	Performance des modèles avec et sans augmentation [30]	38
4.1	Comparaison des performances entre notre modèle et ceux de la littérature	53
4.2	Comparaison des performances entre notre modèle et ceux de l'étude I-IETA 2024 sur le jeu de données ISIC 2019 [34]	54
4.3	Comparaison des performances entre notre modèle et des études récentes sur la classification multiclassées avec le dataset ISIC	58
4.4	Comparaison des performances de différents modèles sur la classification des lésions cutanées [37]	59

Introduction

Contexte général L'utilisation des technologies d'intelligence artificielle (IA) connaît une expansion significative dans divers domaines professionnels, et plus particulièrement dans le secteur médical. Grâce à ses capacités d'analyse avancées et à la puissance de ses algorithmes, l'IA révolutionne les pratiques médicales traditionnelles, allant de l'aide au diagnostic à la prédiction précoce des pathologies complexes. En exploitant de vastes ensembles de données cliniques et d'images médicales, les systèmes intelligents sont aujourd'hui capables de détecter avec une grande précision des anomalies souvent imperceptibles à l'œil humain. Cette avancée technologique ouvre la voie à une médecine plus préventive, plus personnalisée et plus efficace. Dans ce contexte, ce mémoire s'inscrit pleinement dans cette dynamique innovante, en proposant une solution complète, automatisée et basée sur l'intelligence artificielle pour le diagnostic du cancer de la peau. L'objectif principal est de démontrer comment les modèles d'apprentissage profond peuvent contribuer à l'identification précoce des lésions cutanées malignes, favorisant ainsi une meilleure prise en charge des patients et augmentant les chances de traitement curatif.

Problématique De nos jours, le cancer de la peau représente un enjeu de santé publique majeur à l'échelle mondiale. Selon les statistiques les plus récentes, une personne sur cinq développera au cours de sa vie un cancer de la peau non-mélanome, tandis qu'environ une personne sur mille sera atteinte d'un mélanome cutané, forme beaucoup plus agressive et potentiellement mortelle. Ces chiffres alarmants mettent en lumière l'urgence de développer des stratégies innovantes pour améliorer la prévention, la détection et la prise en charge de cette maladie.

Parmi les principaux défis rencontrés, on peut citer la difficulté du diagnostic précoce : certains mélanomes présentent des caractéristiques cliniques similaires à celles de lésions bénignes, rendant leur différenciation visuelle complexe, même pour un professionnel expérimenté. À cela s'ajoute la pénurie de dermatologues spécialisés, notamment dans les zones rurales ou dans les pays à faibles ressources, où l'accès aux soins est souvent limité. Enfin, le coût élevé des procédures diagnostiques constitue un obstacle supplémentaire, freinant l'accès à un dépistage systématique pour de nombreuses populations.

Face à ces enjeux, ce mémoire s'attache à répondre à une problématique centrale, formulée comme suit :

Comment développer une solution technique efficace, économique et fiable permettant de répondre aux besoins identifiés dans la lutte contre le cancer de peau ?

Objectifs du projet Les objectifs généraux de ce projet sont :

- Identifier avec précision les défis et les besoins liés à cette problématique .
- Proposer une architecture complète pour la solution .
- Implémenter une solution technique fonctionnelle et testée .
- Évaluer la performance du système et comparer les résultats aux attentes.

Méthodologie adoptée Pour atteindre ces objectifs, une démarche scientifique sera suivie, reposant sur les étapes suivantes :

1. Étude fonctionnelle et modélisation du système .
2. Développement technique (logiciel/matériel) .
3. Validation par des tests expérimentaux .
4. Analyse des résultats et discussion critique.

Structure du mémoire Ce mémoire est structuré comme suit :

- Le **Chapitre 1** présente les notions de base sur les lésions cutanées et un état de l'art des techniques d'intelligence artificielle appliquées à la dermatologie.
- Le **Chapitre 2** expose les choix technologiques adoptés, notamment en matière de données, de modèles et de matériel.
- Le **Chapitre 3** décrit l'architecture du système développé et ses principaux modules fonctionnels.
- Le **Chapitre 4** analyse les résultats expérimentaux et évalue les performances obtenues.

Une conclusion générale clôture le document en récapitulant les contributions et les perspectives futures.

1 Chapitre 1 : Lésion de peau et technologies

1.1 Introduction

Le cancer de la peau constitue l'une des formes de cancer les plus fréquentes à l'échelle mondiale, avec une incidence en constante augmentation au cours des dernières décennies. Cette pathologie résulte d'une prolifération anormale et incontrôlée des cellules de la peau, généralement induite par une exposition excessive aux rayonnements ultraviolets (UV), qu'ils proviennent du soleil ou de sources artificielles telles que les cabines de bronzage. Si la majorité des cancers cutanés sont relativement bénins et peuvent être traités avec succès lorsqu'ils sont diagnostiqués précocement, certains types, à l'image du mélanome malin, présentent un comportement beaucoup plus agressif. Le mélanome se distingue par son fort potentiel métastatique, c'est-à-dire sa capacité à se propager rapidement à d'autres organes, ce qui en fait l'un des cancers de la peau les plus redoutables et les plus difficiles à traiter à un stade avancé. Ce constat souligne l'importance capitale du dépistage précoce et d'une prise en charge rapide et adaptée.

1.2 Lésions cutanées : Typologie et enjeux médicaux

1.2.1 Peau

La peau constitue la première ligne de défense de l'organisme face aux agressions extérieures, telles que les agents pathogènes, les rayonnements ultraviolets ou encore les substances chimiques. En plus de son rôle protecteur, elle participe à la régulation thermique, à la synthèse de la vitamine D et au maintien de l'homéostasie. Anatomiquement, comme illustré dans la figure 1.1, la peau est organisée en trois couches principales :

- **l'épiderme**, qui est la couche superficielle assurant une fonction barrière contre l'environnement extérieur ;

- **le derme**, situé en dessous, riche en vaisseaux sanguins, en terminaisons nerveuses et en fibres de collagène, jouant un rôle crucial dans le soutien et la nutrition de l'épiderme ;
- et enfin, **l'hypoderme**, ou tissu sous-cutané, composé principalement de cellules adipeuses, qui assure une fonction d'amortissement et d'isolation thermique.




FIGURE 1.1 – les trois couches de peau

1.2.2 Lésions cutanées

Les lésions cutanées désignent des altérations visibles de la peau, pouvant survenir en surface ou en profondeur. Elles peuvent être congénitales (présentes dès la naissance) ou acquises (apparaître secondairement). Elles se distinguent par leur forme, leur couleur et leur texture (lisse, rugueuse, squameuse, cireuse, etc.) [1].

D'un point de vue médical, nous distinguons trois grandes catégories de lésions :

- **Les lésions élémentaires primaires** : ce sont les lésions d'apparition initiale, telles que les macules (pigmentées, rouges ou achromiques), les papules, nodules, végétations, ainsi que les lésions liquidiennes comme les vésicules, bulles ou pustules.
- **Les lésions élémentaires secondaires** : elles résultent de l'évolution ou de la modification des lésions primaires (ex. : croûtes, squames, cicatrices).
- **Les tumeurs cutanées** : elles représentent une prolifération anormale de cellules cutanées et peuvent être bénignes ou malignes.

1.2.3 Tumeurs cutanées

Les **tumeurs bénignes** de la peau sont des lésions non cancéreuses, ne présentant pas de risque de métastase. Elles sont généralement sans conséquences graves, bien que certaines puissent nécessiter une ablation chirurgicale à des fins esthétiques ou de prévention. Les formes fréquentes des tumeurs cutanées bénignes incluent : la kératose séborrhéique, le lentigo solaire, le naevus mélanocytaire acquis, le dermatofibrome ou encore le kérato-acanthome.

Certaines lésions bénignes particulières, comme le naevus mélanocytaire congénital ou la kératose actinique, présentent un potentiel de transformation maligne et requièrent donc un suivi dermatologique régulier [1].

Les **tumeurs cutanées malignes**, quant à elles, regroupent les cancers de la peau. La majorité des cancers cutanés prennent naissance au niveau de l'épiderme, la couche la plus externe de la peau. Parmi ces cancers, nous distinguons deux grandes catégories selon le type cellulaire à l'origine de la prolifération : les **mélanomes**, issus des mélanocytes, et les **carcinomes**, qui se développent à partir des kératinocytes, caractérisés par une prolifération excessive et incontrôlée de cellules[1].

Nous distinguons principalement trois types de tumeurs cutanée malignes :

- **Le mélanome** : issu des mélanocytes, particulièrement agressif et présente un fort potentiel de métastases. Il peut évoluer en surface ou en profondeur, et reste l'une des causes principales de mortalité par cancer cutané.
- **Le carcinome épidermoïde (ou spinocellulaire)** : il se développe à partir des kératinocytes de l'épiderme. Il progresse rapidement et peut atteindre les tissus voisins et d'autres organes.
- **Le carcinome basocellulaire** : le plus fréquent des cancers de la peau, issu des cellules basales. Il présente un risque de métastases faible, mais doit être traité pour éviter des atteintes locales destructrices.

1.2.4 Mélanome cutané

Le mélanome cutané est le cancer de la peau le plus redouté en raison de son fort potentiel métastatique, bien qu'il soit le moins fréquent. Il naît à partir des mélanocytes, cellules pigmentaires situées dans l'épiderme, et peut également survenir dans d'autres localisations où ces cellules sont présentes, comme l'œil (mélanome oculaire).

Bien que le mélanome puisse apparaître sur toutes les zones du corps, il est plus fréquent dans les régions exposées au soleil.

1.2.5 Carcinomes cutanés

Les carcinomes cutanés sont plus fréquents mais généralement moins graves. Elles regroupent principalement deux types :le **carcinome basocellulaire** et le **carcinome épidermoïde**.

- **Carcinome basocellulaire** : ce type de cancer se développe a partir des kératinocytes de la couche basale de l'épiderme. Il représente la forme la plus courante des cancers cutanés et se manifeste souvent sous forme de nodules perlés localisés au niveau du visage, du cou ou du tronc. Bien que son évolution soit lente et que le risque de métastases soit extrêmement faible, l'absence de traitement peut conduire

à une invasion locale importante, atteignant parfois les structures profondes telles que le cartilage ou l'os.

- **Carcinome épidermoïde** : ce type de carcinome prend naissance dans la couche intermédiaire de l'épiderme. Il affecte principalement les zones exposées au soleil ou les muqueuses, mais peut également se développer à partir de lésions cutanées préexistantes telles que les kératoses actiniques, les cicatrices ou encore les ulcères chroniques. Ce dernier présente un risque métastatique plus élevé que le carcinome basocellulaire, en particulier en l'absence de prise en charge rapide.
- **Le carcinome épidermoïde** : le **carcinome épidermoïde cutané** (également appelé *carcinome spinocellulaire*) est un *cancer de la peau d'origine kératinocytaire* qui représente le *deuxième type de cancer cutané le plus fréquent*, après le carcinome basocellulaire. Il se développe à partir des *cellules de l'épiderme*, en particulier celles de la *couche épineuse* (ou spinocellulaire), d'où son nom histologique. Ce type de carcinome se manifeste cliniquement par une *lésion squameuse, indurée*, parfois ulcérée, et peut apparaître sur les zones photo-exposées. Bien que généralement *moins agressif que le mélanome*, il possède un *potentiel métastatique non négligeable*, notamment lorsqu'il est localisé sur les lèvres ou les oreilles, ou en cas d'immunodépression. Son développement est fortement lié à *l'exposition chronique aux rayons ultraviolets*, mais aussi à des facteurs comme les infections à papillomavirus (HPV) ou les lésions précancéreuses comme la kératose actinique.

Selon l'Organisation mondiale de la santé, les carcinomes épidermoïdes représentent une *part croissante des cancers cutanés dans les pays à fort ensoleillement*, en particulier chez les sujets à peau claire [2].

1.2.6 Formes rares : Carcinome à cellules de Merkel

Un troisième type plus rare mais agressif, le **carcinome à cellules de Merkel**, peut également se développer à partir des cellules neuroendocrines de l'épiderme. Bien que son incidence soit faible, il touche majoritairement les personnes âgées à peau claire et tend à se localiser sur les régions exposées au soleil.

La compréhension des mécanismes biologiques et des facteurs de risque associés aux cancers cutanés est essentielle pour améliorer les stratégies de dépistage, de prévention et de traitement. Dans cette optique, l'émergence de nouvelles technologies, notamment les outils d'intelligence artificielle, offre des perspectives prometteuses pour améliorer la détection précoce et la classification des lésions cutanées.

1.3 Contraintes et problématiques médicales

Les principales difficultés dans la prise en charge des maladies de peau sont :

- Le diagnostic du cancer de la peau demeure souvent tardif, en particulier chez les personnes à peau foncée. Par exemple les hommes noirs ont un taux de survie de seulement 52%, contre 75% chez les hommes blancs, principalement à cause d'un diagnostic trop tardif [3]
- Les techniques actuelles reposent sur l'examen visuel suivi d'une biopsie. Toutefois, des erreurs de diagnostic peuvent survenir, ce qui peut entraîner un retard dans la prise en charge.
- En Afrique, l'accès aux traitements spécialisés comme la chirurgie de Mohs reste très restreint, faute de professionnels qualifiés, de ressources économiques, et à cause de certaines barrières culturelles.
- Malgré les risques connus liés aux UV, les comportements à risque persistent, tels que l'usage des cabines de bronzage. Ces pratiques sont parfois encouragées par des célébrités, ce qui nuit aux efforts de prévention.

1.4 Avancées technologiques dans la dermatologie

Les avancées technologiques ont profondément transformé la dermatologie moderne. Cette section présente les contributions majeures de l'intelligence artificielle, de l'imagerie médicale, des nanotechnologies, de la médecine personnalisée et de la télémédecine dans le diagnostic et le traitement des maladies cutanées.

1.4.1 Médecine personnalisée et médecine régénérative

La médecine personnalisée repose sur l'analyse approfondie des caractéristiques individuelles d'un patient, notamment ses données génétiques, biologiques et environnementales, afin de proposer des traitements sur mesure. En dermatologie, cette approche trouve une application particulièrement prometteuse dans la prise en charge des cancers cutanés, notamment le mélanome, dont l'évolution et la réponse thérapeutique varient considérablement d'un individu à l'autre [4].

Grâce aux progrès de la génomique et de la biologie moléculaire, il est désormais possible d'identifier des mutations spécifiques (comme celles affectant le gène BRAF présent dans environ 50% des mélanomes) qui orientent le choix de thérapies ciblées [4]. Par ailleurs, l'immunothérapie personnalisée, fondée sur la stimulation du système immunitaire via

des inhibiteurs de checkpoints (anti-PD1/CTLA-4), a révolutionné le traitement des mélanomes avancés, avec des taux de réponse atteignant 40-60% selon les profils tumoraux [4, 5].

La médecine régénérative représente une approche émergente prometteuse pour le traitement des lésions cutanées complexes. En mobilisant des cellules souches mésenchymateuses ou des facteurs de croissance plaquettaires (PRP), cette discipline vise à restaurer les fonctions cutanées. Les résultats sont particulièrement encourageants dans la prise en charge des brûlures étendues et des ulcères chroniques [6].

Ainsi, l'intégration synergique de la médecine personnalisée (basée sur la génomique tumorale) et régénérative (fondée sur les thérapies cellulaires) en dermatologie marque une avancée transformationnelle vers une prise en charge plus précise et centrée sur le patient [4, 6]

1.4.2 Télémédecine et suivi à distance

La télédermatologie, branche spécifique de la télémédecine appliquée aux maladies de la peau, a connu une croissance fulgurante avec l'essor des technologies numériques. Cette approche repose sur l'échange d'informations cliniques par outils numériques, permettant une évaluation fiable des lésions cutanées sans contact physique, avec une concordance diagnostique atteignant 85-92% pour les carcinomes basocellulaires.[7] Ses principaux avantages incluent :

- Des consultations à distance fiables grâce à la transmission d'images haute résolution, particulièrement lorsque combinée à la télédermoscopie (amélioration de 20-25% de la précision diagnostique selon nikolakis2024teledermatology)
- Un suivi régulier optimisé pour les patients ruraux ou à mobilité réduite, réduisant les délais de consultation de 50% (passant de 50-58 jours à 28-35 jours)
- Un triage efficace des cas urgents, avec orientation accélérée vers biopsie (délai moyen réduit à 104 jours contre 125 jours en parcours conventionnel)

1.4.3 Imagerie avancée

Les avancées récentes en technologies d'imagerie médicale ont considérablement renforcé les capacités diagnostiques en dermatologie, en offrant des outils non invasifs à haute résolution permettant une analyse plus fine et plus objective des lésions cutanées. Parmi ces technologies innovantes, nous distinguons :

- La **dermoscopie numérique**, qui permet non seulement d'améliorer la visualisation des structures sous-épidermiques invisibles à l'œil nu, mais aussi de stocker les images de manière séquentielle afin d'en suivre l'évolution dans le temps. Cette fon-

tionnalité est essentielle pour le dépistage précoce du mélanome et la surveillance de patients à risque.

- La **microscopie confocale à balayage laser (RCM)**, qui offre une imagerie en temps réel des structures cellulaires de l'épiderme avec une résolution quasi histologique, sans nécessiter de prélèvement tissulaire. Elle constitue une alternative prometteuse à la biopsie dans certains cas, notamment pour la délimitation des marges tumorales dans les carcinomes basocellulaires.
- L'**Optical Coherence Tomography (OCT)**, qui permet une visualisation en coupe verticale des tissus jusqu'au derme superficiel, complète efficacement la RCM en offrant une meilleure évaluation de la profondeur des lésions.
- La **microscopie confocale à fluorescence ex vivo (FCM)**, utilisée après excision, permet une évaluation rapide et fiable des marges tumorales, comparable à l'analyse histologique conventionnelle.

L'intégration combinée du RCM et de l'OCT in vivo, suivie du FCM ex vivo, permet d'atteindre une sensibilité de 100% et une spécificité de 96,3% dans la détection des marges tumorales du carcinome basocellulaire [8]. Cette approche multimodale, non invasive et reproductible, pourrait significativement améliorer la précision diagnostique en préopératoire, réduire les réinterventions, et rapprocher les performances de l'imagerie de celles observées avec la chirurgie de Mohs.

Ces technologies d'imagerie avancée, intégrées à des outils d'aide au diagnostic automatisé, offrent de nouvelles perspectives pour une dermatologie plus précise, plus rapide et moins invasive.

1.4.4 Nanotechnologie

Les nanotechnologies représentent un domaine en pleine expansion offrant des solutions innovantes dans le soin, le diagnostic et la prévention des maladies dermatologiques. En manipulant des matériaux à l'échelle nanométrique (inférieure à 100 nm), on améliore significativement la solubilité, la stabilité et la biodisponibilité des agents thérapeutiques.

Parmi les applications les plus prometteuses, nous citons [9] :

- Le **ciblage thérapeutique précis**, grâce aux nanoparticules lipidiques, polymériques ou métalliques (comme l'or ou l'argent), qui assurent une libération contrôlée des principes actifs directement dans les tissus affectés — utile notamment dans l'acné, le psoriasis ou les lésions cancéreuses.
- La **photoprotection avancée**, via l'utilisation de nanoparticules d'oxyde de zinc ou de dioxyde de titane, qui offrent une meilleure filtration UV tout en améliorant la transparence et la stabilité des formulations topiques.

Ces avancées, combinées à l'émergence des nanocapteurs et des systèmes activables par stimuli, ouvrent la voie à une dermatologie plus ciblée, personnalisée et moins invasive [chakraborty2024nanoparticles](#).

1.4.5 Intelligence Artificielle et apprentissage automatique

L'intelligence artificielle (IA) joue un rôle croissant dans le domaine de la dermatologie, en particulier dans le diagnostic assisté par image. Grâce aux avancées de l'*apprentissage automatique* (*machine learning*) et plus spécifiquement de l'*apprentissage profond* (*deep learning*), les modèles de type réseaux neuronaux convolutifs (CNN) ont démontré leur capacité à analyser des images dermoscopiques avec une précision remarquable.

Un modèle basé sur un réseau de neurones convolutifs (CNN) a atteint une performance équivalente à celle de 21 dermatologues expérimentés pour la classification de diverses lésions cutanées, notamment les mélanomes, carcinomes et kératoses [10]. Ces résultats soulignent le potentiel important de l'intelligence artificielle comme outil d'aide à la décision clinique, en particulier pour le triage, le diagnostic différentiel et le suivi des lésions suspectes.

Par ailleurs, ces technologies sont désormais intégrées dans des applications mobiles accessibles au grand public. Ces applications permettent aux patients de réaliser un auto-dépistage préliminaire en photographiant leurs lésions cutanées. Les algorithmes intégrés fournissent une évaluation instantanée du risque, ce qui facilite le triage précoce des cas potentiellement graves et encourage une consultation médicale rapide en cas de suspicion.

L'intelligence artificielle représente ainsi un atout majeur pour renforcer l'accessibilité, accélérer le processus diagnostique et en améliorer la précision en dermatologie, tout en apportant un soutien précieux aux professionnels de santé confrontés à une demande croissante et à un déficit de spécialistes dans certaines zones géographiques.

1.5 Évolution de l'intelligence artificielle en dermatologie

L'intelligence artificielle a connu une évolution fulgurante en dermatologie, passant en une décennie de simples preuves de concept à des outils cliniques opérationnels. Cette transformation sans précédent s'appuie sur une convergence unique entre des avancées algorithmiques majeures, la disponibilité croissante de données dermatologiques numérisées, et une demande accrue pour des solutions diagnostiques rapides et accessibles.

Le développement de l'IA dans ce domaine a été particulièrement marqué par l'émergence de réseaux neuronaux profonds spécialisés dans l'analyse d'images, capables de dé-

tecter des motifs invisibles à l'œil humain. Ces systèmes ont bénéficié d'une amélioration continue de leur architecture, combinée à une explosion de la puissance computationnelle, permettant l'analyse en temps réel de lésions cutanées avec une précision toujours croissante.

Parallèlement, l'apparition de vastes bases de données annotées par des experts, comme celles de l'ISIC (International Skin Imaging Collaboration), a fourni le carburant nécessaire à l'entraînement de ces modèles sophistiqués. Cette synergie entre progrès techniques et ressources médicales a permis à l'IA de dépasser le stade du simple prototype de laboratoire pour devenir un véritable outil d'aide à la décision clinique.




FIGURE 1.2 – Évolution du nombre de publications et des citations sur l'intelligence artificielle appliquée à la dermatologie cutanée entre 1991 et 2023. Source : [11].

La Figure 1.2 illustre l'évolution du nombre de publications et de citations scientifiques liées à l'intelligence artificielle appliquée à la dermatologie cutanée entre 1991 et 2023. Cette tendance reflète un intérêt croissant et soutenu de la part de la communauté scientifique. Longtemps marginale, la recherche dans ce domaine a connu une croissance exponentielle à partir de la seconde moitié des années 2010, portée par les avancées rapides en apprentissage profond. Cette dynamique traduit une maturation progressive du champ, passant d'explorations initiales à des applications concrètes, cliniquement pertinentes. C'est dans ce contexte que se sont succédé les principales étapes du développement de l'IA en dermatologie, depuis les premières preuves de concept jusqu'aux validations cliniques récentes.

1.5.1 Premières avancées (2010–2017) : Démonstration de faisabilité

En 2017, une étude pionnière publiée a montré qu'un réseau de neurones convolutifs était capable de classer les lésions cutanées avec une précision comparable à celle de dermatologues expérimentés [10]. Le modèle reposait sur de vastes ensembles de données, notamment ceux fournis par l'International Skin Imaging Collaboration (ISIC), posant ainsi les fondations de l'application de l'apprentissage automatique en dermatologie.

1.5.2 Expansion et validation (2018–2020) : comparaisons homme–machine

En 2018, les performances diagnostiques d'un réseau de neurones convolutifs (CNN) ont été comparées à celles de 58 dermatologues, montrant que l'intelligence artificielle surpassait les praticiens dans plusieurs situations cliniques [12].

En 2020, des résultats similaires ont été confirmés, tout en mettant en évidence certaines limites de l'intelligence artificielle en conditions réelles, notamment face à la variabilité des images et à la nécessité de prendre en compte le contexte clinique dans l'établissement des diagnostics [13].

1.5.3 Applications cliniques (2021–2023) : collaboration IA–médecins

La période récente a vu l'intégration progressive de l'IA dans la pratique clinique. winkler2023assessment, dans une étude parue en 2023, ont montré que les dermatologues amélioraient leur performance diagnostique lorsqu'ils étaient assistés par un CNN.

Dans un cadre clinique réel, l'IA a été comparé à des experts pour le diagnostic de cancers cutanés via téléphone mobile. Bien que l'IA se soit montrée prometteuse, des problèmes de spécificité ont été relevés.[14]

1.5.4 Défis persistants et orientations futures

Plusieurs défis restent à relever parmi lesquels nous citons :

- **Généralisation** : Les performances de l'IA diminuent sur les peaux foncées.[15]
- **Sensibilité aux artefacts** : La qualité des images, l'éclairage ou les objets parasites peuvent fausser les prédictions [16].
- **Transparence et régulation** : Le besoin de normes claires [17] s'impose pour assurer la reproductibilité, la responsabilité et la sécurité des systèmes d'IA en santé,

en particulier face au manque de rigueur dans la validation des modèles et à l'opacité des données utilisées pour leur entraînement.,

- **Intégration clinique** : L'acceptation des cliniciens, le coût et l'interopérabilité restent des freins majeurs.

1.5.5 Tendances futures (2024 et au-delà)

Les perspectives les plus prometteuses incluent :

- Le développement de systèmes d'IA explicable (XAI), pour renforcer la confiance des praticiens.
- La combinaison de l'IA avec des technologies comme la microscopie confocale ou la tomographie par cohérence optique (OCT) soglia2022diagnostics.
- Un dépistage personnalisé, notamment pour les patients à haut risque avec de multiples naevus.

1.5.6 Apports de l'IA dans la prise en charge dermatologique : perspectives patients et praticiens

L'intelligence artificielle apporte des solutions innovantes pour répondre aux besoins cliniques des **patients** et des **médecins** en dermatologie.

Impact de l'IA sur le parcours de soins des patients

L'intégration de l'intelligence artificielle dans le parcours de soins offre aux patients de nouvelles perspectives en matière de dépistage, de diagnostic, d'accès aux soins et de prévention, comme en témoignent les avancées présentées ci-dessous :

- **Diagnostic rapide et accessible** :
 - Détection précoce des cancers cutanés (mélanome,carcinomes)
 - Réduction des délais d'attente pour consultation spécialisée
- **Amélioration de la précision diagnostique** :
 - Réduction des erreurs de diagnostic (faux négatifs)
 - Suivi automatisé des lésions chroniques (psoriasis,eczéma)
- **Accès aux soins en zones rurales** :
 - Solutions de dépistage par smartphone
 - Télé-expertise pour populations éloignées
- **Éducation et prévention** :
 - Outils interactifs d'auto-surveillance
 - Recommandations personnalisées de protection solaire

Impact de l'IA sur le parcours de soins les médecins

Du côté des professionnels de santé, l'intelligence artificielle constitue un outil d'assistance précieux, contribuant à optimiser les décisions cliniques, à rationaliser les processus diagnostiques et à améliorer le suivi des patients au quotidien :

- **Aide à la décision (CADx) :**
 - Classification des lésions avec scores de confiance
 - Priorisation des cas urgents
- **Gain de temps et efficacité :**
 - Tri automatique des images dermatoscopiques
 - Génération de rapports pré-remplis
- **Standardisation des diagnostics :**
 - Réduction des variations inter-opérateurs
 - Meilleure reproductibilité des évaluations
- **Suivi des pathologies chroniques :**
 - Analyse quantitative de l'évolution des lésions
 - Détection précoce des rechutes

1.6 Conclusion

La lutte contre les maladies de peau, en particulier le cancer, est un enjeu médical majeur. Les technologies modernes offrent de nouvelles possibilités pour améliorer le diagnostic et l'accès aux soins. L'IA s'intègre dans cette évolution, en apportant une réponse concrète à des problématiques toujours présentes.

2 Chapitre 2 : Système Proposé et Choix de technologies

2.1 Introduction

Le diagnostic précoce du cancer de la peau représente un enjeu majeur de santé publique, en particulier face à la recrudescence des cas de mélanome et à la disparité d'accès aux soins dermatologiques spécialisés. Dans ce contexte, les avancées récentes en intelligence artificielle (IA) et en traitement d'image offrent de nouvelles opportunités pour automatiser l'analyse visuelle des lésions cutanées, avec des performances prometteuses en matière de détection et de classification.

Cependant, le développement d'une telle solution nécessite bien plus que l'application brute d'algorithmes d'IA. Il s'agit d'une démarche globale, impliquant des choix technologiques cohérents à chaque niveau de conception : sélection des bases de données pertinentes, choix d'architectures de modèles adaptés à la tâche, stratégies d'optimisation, et enfin, identification des plateformes matérielles capables d'assurer une inférence rapide, fiable et autonome.

Ce chapitre présente donc, dans un premier temps, le système de diagnostic automatisé que nous proposons, puis détaille les choix technologiques qui ont guidé sa conception. L'objectif est de montrer comment des décisions techniques, fondées sur une analyse comparative rigoureuse, permettent de construire un outil efficace, robuste et potentiellement déployable dans des contextes réels, y compris à faibles ressources.

2.2 Présentation du système *DermAI-Detect*

Le système proposé, nommé *DermAI-Detect*, a été conçu dans l'objectif de fournir une solution complète, fiable et accessible pour le diagnostic automatisé du cancer de la peau, avec un accent particulier sur la détection du mélanome, l'un des types les plus agressifs.

S'appuyant sur les dernières avancées en intelligence artificielle, *DermAI-Detect* intègre plusieurs composantes complémentaires : l'analyse d'images dermatologiques issues de bases de données spécialisées, l'utilisation des techniques d'AI pour la classification des

lésions, ainsi qu’une plateforme centralisée permettant la collecte, la mise à jour continue et la gestion des données cliniques.

Cette approche intégrée vise non seulement à améliorer la précision du diagnostic, mais aussi à faciliter le suivi des patients, et à favoriser le déploiement de la solution dans des environnements à ressources limitées grâce à une interface conviviale et légère. *DermAI-Detect* s’inscrit ainsi dans la dynamique d’une médecine préventive, connectée et intelligemment assistée.

2.3 Objectives fixé pour notre système

Le présent travail s’inscrit dans cette dynamique d’innovation. Il vise à proposer un système basé sur l’intelligence artificielle pour :

- Permettre un diagnostic automatique et fiable du cancer de la peau à partir d’images dermoscopiques .
- Réduire la dépendance à l’expertise médicale en zones sous-équipées.
- Fournir une solution accessible, portable et à faible coût.
- Offrir un outil de soutien à la décision pour les professionnels de santé.

2.4 Choix de la base de données

Le choix de la base de données constitue une étape critique dans le développement du système DermAI. Plusieurs bases de données publiques sont disponibles, chacune présentant des avantages et des limitations spécifiques.

Parmi les bases les plus couramment utilisées, on retrouve l’**ISIC Archive** (plus de 30 000 images dermoscopiques) et **HAM10000** (10 015 images), qui offrent un volume important d’images annotées de haute qualité [18]. Toutefois, ces deux bases souffrent d’un *biais démographique important*, les images provenant majoritairement de patients à phototypes clairs (Fitzpatrick I–III), ce qui affecte la performance des modèles sur les peaux foncées [18]. De plus, les lésions bénignes y sont fortement surreprésentées par rapport aux lésions malignes, engendrant un *déséquilibre de classes* qui peut induire un biais prédictif.

D’autres bases telles que **PH2** (200 images) se distinguent par la qualité de l’annotation (segmentation manuelle et diagnostic histologique), mais leur faible taille les rend plus adaptées à la validation qu’à l’entraînement [18]. La base **PAD-UFES-20**, composée d’images cliniques prises par smartphone dans des contextes réels au Brésil, est particulièrement précieuse pour tester la robustesse des modèles en conditions de terrain, notamment pour les peaux foncées [18].

Enfin, des jeux de données tels que **Dermofit**, **Derm7pt**, ou **MED-NODE** proposent des photos cliniques (non dermoscopiques), ce qui les rend pertinents pour des systèmes embarqués utilisant des caméras classiques [18].

Recommandations :

- Utiliser un corpus large et diversifié pour l’entraînement (ex. : ISIC, BCN20000).
- Valider sur des bases contenant des phototypes variés (ex. : PAD-UFES).
- Tester sur des images cliniques standards pour s’adapter aux usages sur smartphone.
- Appliquer des techniques d’augmentation de données et d’équilibrage de classes pour améliorer la robustesse.

Ces choix garantissent une meilleure généralisation du modèle, tout en assurant sa pertinence dans des contextes médicaux ou semi-médicaux variés, notamment en zones rurales ou à faibles ressources.

Choix de la base ISIC 2019 dans notre cas : Dans le cadre de notre projet, nous avons choisi d’utiliser la base **ISIC 2019** car elle représente une version enrichie du référentiel ISIC, contenant 25 331 images annotées, réparties en huit catégories cliniques distinctes. Ces catégories incluent à la fois des lésions bénignes et malignes :

- **Melanoma (MEL)** – *Malin* : 4 522 images. Lésion hautement agressive, à fort potentiel métastatique.
- **Melanocytic nevus (NV)** – *Bénin* : 12 875 images. Grain de beauté commun sans risque immédiat.
- **Basal cell carcinoma (BCC)** – *Malin* : 3 323 images. Cancer de la peau le plus fréquent, à croissance lente mais destructrice localement.
- **Actinic keratosis (AK)** – *Précancéreux / considéré comme malin* : 867 images. Bien qu’initialement bénigne, cette lésion a un fort potentiel de transformation en carcinome épidermoïde (SCC), ce qui justifie son regroupement avec les lésions malignes dans notre cas [18].
- **Benign keratosis (BKL)** – *Bénin* : 2 624 images. Inclut kératoses séborrhéiques, lichens plans kératosiques.
- **Dermatofibroma (DF)** – *Bénin* : 239 images. Nodule cutané bénin d’origine fibroblastique.
- **Vascular lesion (VASC)** – *Bénin* : 253 images. Taches rubis, hémangiomes, etc.
- **Squamous cell carcinoma (SCC)** – *Malin* : 628 images. Cancer cutané agressif, souvent dérivé d’une AK non traitée.

Ce dataset est compatible avec les approches d'apprentissage profond nécessitant un grand volume d'images, et il est particulièrement adapté à l'entraînement de modèles multi-classes ou binaires via regroupement ciblé des étiquettes. Par ailleurs, la diversité institutionnelle des images (provenant de plusieurs pays et centres cliniques) permet d'améliorer la capacité de généralisation du modèle entraîné [18]. La présence d'un format structuré (métadonnées cliniques, masques de segmentation dans certains cas) facilite également les traitements supervisés et les tests de robustesse en conditions simulées.

2.5 Sélection de la Carte Embarquée pour le Système Ciblé

Le déploiement du système DermAI de détection automatique du cancer de la peau dans des environnements réels, notamment en zones rurales, impose des contraintes strictes en termes de coût, d'autonomie énergétique, de traitement local (hors ligne), et de simplicité d'usage. Pour cela, plusieurs plateformes embarquées ont été étudiées et comparées [18], selon leurs performances d'inférence, compatibilité avec les frameworks IA, coût, consommation énergétique et facilité d'intégration.

Cartes évaluées

- **Raspberry Pi 4 + Camera Module 3** : Équipé d'un processeur ARM Cortex-A72 (quad-core 1.5 GHz) et jusqu'à 8 GB de RAM, cette carte exécute des modèles quantifiés comme MobileNetV2 à ~30 fps (~33 ms/image). Compatible avec TensorFlow Lite, PyTorch Mobile et ONNX Runtime. Elle offre une flexibilité logicielle élevée pour un coût total d'environ 80 € [18].
- **Jetson Nano (NVIDIA)** : Doté d'un CPU ARM Cortex-A57 et d'un GPU Maxwell (128 cœurs), il est optimisé pour l'inférence accélérée via TensorRT (3 fps pour MobileNetV2 quantifié). Bien que performant, son coût (~100 €) et sa consommation (5–10 W) sont plus élevés [18].
- **Google Coral Edge TPU (USB Accelerator)** : Ce coprocesseur spécialisé permet une inférence ultra-rapide (2.5 ms/image) avec les modèles TFLite quantifiés (int8). Néanmoins, il nécessite une carte hôte (Raspberry Pi, par exemple) et n'est compatible qu'avec TFLite [18].
- **ESP32-CAM** : Microcontrôleur très économique (5–10 €) avec caméra intégrée (2MP), capable d'exécuter des petits modèles TinyML à ~9 fps. Sa faible mémoire (520 KB) limite fortement son usage à des tâches simples [18].
- **Arduino Nicla Vision** : Carte STM32 avec capteur d'image et connectivité intégrée, compatible avec TensorFlow Lite Micro. Elle exécute des variantes de Mo-

bileNet à $\sim 100\text{--}200$ ms/image, mais reste peu adaptée à des applications de vision médicale complexes [18].

Justification du choix À l’issue de cette étude comparative, la plateforme **Raspberry Pi 4 + Camera Module 3** a été retenue comme solution optimale pour le prototype final. Ce choix est justifié par plusieurs avantages décisifs :

- **Performance** : Capable de réaliser des inférences en temps réel (10–30 ms/image avec ResNet50 quantifié), elle satisfait les exigences de réactivité pour un usage clinique de terrain [18].
- **Autonomie et consommation** : Sa consommation modérée (~ 5 W) permet une alimentation via batterie ou secteur, ce qui est crucial en contexte rural [18].
- **Flexibilité logicielle** : Elle supporte une large gamme de frameworks modernes (TensorFlow Lite, ONNX Runtime, PyTorch Mobile), facilitant l’intégration des modèles IA [18].
- **Coût maîtrisé** : Le coût global (~ 80 €) en fait une solution économiquement viable pour des déploiements à large échelle dans des régions à faibles ressources [18].
- **Utilisation hors ligne** : L’inférence s’effectue localement sans dépendance à une connexion Internet, ce qui assure robustesse et confidentialité des données [18].

Ainsi, la solution retenue offre un compromis équilibré entre puissance de calcul, coût, faible consommation et compatibilité avec les exigences d’un usage médical mobile et autonome.

2.6 Choix des modèles

2.6.1 Premier choix exploré : Méthodes de traitement d’image classiques

Avant l’essor de l’apprentissage profond, la classification d’images médicales reposait principalement sur des techniques de traitement d’image dites classiques. Celles-ci combinent généralement une phase d’extraction manuelle de caractéristiques visuelles avec une classification supervisée à l’aide de modèles comme les SVM, les forêts aléatoires ou les k-plus proches voisins.

Histogram of Oriented Gradients (HOG) Proposé par Dalal et Triggs (2005) pour la détection de piétons, HOG est basé sur l’histogramme des orientations de gradient dans des régions localisées de l’image [19]. Il permet de capturer la forme et la structure locale des objets, ce qui en fait un descripteur populaire pour des formes géométriques simples.

Toutefois, dans le contexte de l'analyse dermatologique, HOG est limité par sa sensibilité au bruit de texture et par sa faible capacité à modéliser les motifs visuels complexes, irréguliers et multiformes des lésions cutanées.

Algorithme de Viola-Jones Développé en 2001, l'algorithme de Viola-Jones repose sur l'extraction de caractéristiques de Haar, l'apprentissage avec l'algorithme AdaBoost et l'utilisation de classifieurs en cascade [20]. Conçu pour la détection faciale en temps réel, il s'avère rapide et efficace pour des structures régulières et bien contrastées. Cependant, il montre des performances médiocres sur des images médicales avec des textures peu définies et des contrastes faibles. Il n'est donc pas directement applicable à la détection de tumeurs ou de lésions dermatologiques sans adaptation majeure.

Deformable Part Models (DPM) Les DPM, représentent les objets comme une collection de parties flexibles organisées dans une structure déformable. Chaque partie est modélisée à l'aide de caractéristiques locales (souvent HOG) et un modèle global incorpore les relations spatiales entre les parties. Bien que performants pour la détection d'objets naturels, les DPM requièrent des annotations précises des parties constitutives et sont coûteux en temps de calcul. Dans un cadre médical, leur application est rendue difficile par la grande variabilité morphologique des lésions et le manque de standardisation des formes.[21]

Correspondance de modèles (Template Matching). La correspondance de modèles repose sur la comparaison directe d'une région d'image avec un modèle préenregistré à l'aide de métriques telles que la corrélation croisée ou la distance euclidienne [22]. Elle est simple à mettre en œuvre, mais très sensible aux changements d'échelle, de rotation, de contraste et de position. Cela en fait une technique peu robuste pour les images dermatologiques où les lésions varient fortement en apparence et en taille.

Limites générales Ces approches classiques présentent plusieurs limitations majeures :

- **Extraction manuelle de caractéristiques** :les descripteurs doivent être conçus manuellement, ce qui nécessite une expertise préalable du domaine.
- **Faible capacité de généralisation** : ces méthodes échouent souvent à capturer la complexité visuelle des images médicales, riches en variations inter-/intra-patients.
- **Sensibilité au bruit et aux artefacts** :les images médicales contiennent souvent du bruit (poils, ombres, artefacts optiques) qui perturbe les descripteurs classiques.

En raison de ces limites, ces méthodes sont aujourd'hui principalement utilisées à des fins comparatives ou comme étape préliminaire d'extraction de caractéristiques dans des pipelines hybrides.

2.6.2 Deuxieme choix exploré Réseaux de Neurones Artificiels (ANN)

Les ANN sont composés de couches de neurones interconnectés, utilisant des fonctions d'activation non linéaires pour modéliser des relations complexes. Dans un contexte de vision par ordinateur, les ANN nécessitent une phase d'extraction de caractéristiques préalable, ce qui limite leur autonomie et robustesse face à la variabilité des données médicales.

Les ANN ont également été testés pour la classification binaire des lésions cutanées. Ils fonctionnent via un ensemble de couches denses ajustées par rétropropagation. Toutefois, leur efficacité dépend fortement de la qualité de l'extraction manuelle des caractéristiques (ex : ondelettes 2D, matrices de co-occurrence GLCM, seuillage par entropie). Les précisions observées varient entre 86,6% [23] et 97.09% [24], mais ces réseaux s'avèrent sensibles aux artefacts visuels et requièrent une préparation des données plus complexe. Bien que simples à implémenter, ces approches exigent une extraction manuelle des caractéristiques et se montrent peu efficaces pour capturer la complexité des images médicales. Elles manquent également de robustesse face à la variabilité inter-patients.

2.6.3 Troisieme choix exploré Réseaux auto-organisants de Kohonen (SOM)

Les Self-Organizing Maps sont des réseaux non supervisés qui projettent des données multidimensionnelles dans un espace de plus faible dimension (souvent 2D). Ils permettent de détecter des similarités entre échantillons, mais ne sont pas optimisés pour des tâches de classification supervisée, en particulier sur des images médicales bruitées. Bien qu'elles offrent de bonnes performances (de 93,15% jusqu'à 98,3% de précision [25]), elles souffrent de plusieurs limitations :

- Besoin d'extraction manuelle de caractéristiques.
- Moindre efficacité face aux méthodes supervisées modernes.
- Sensibilité au bruit et aux variations des données.

En raison de leur caractère exploratoire et non supervisé, les KNN ne conviennent pas comme solution principale .

2.6.4 Quatrieme choix exploré Réseaux de Neurones Convolutifs (CNN)

Les réseaux neuronaux convolutifs (CNN) constituent aujourd'hui l'état de l'art en matière de reconnaissance d'images et d'analyse visuelle automatisée. Ils ont été spécifi-

quement conçus pour traiter des données structurées en grille, comme les images, en tirant parti de leurs propriétés spatiales locales. Contrairement aux réseaux de neurones classiques (ANN) ou aux approches traditionnelles comme les k-plus proches voisins (KNN), les CNN permettent une extraction automatique et hiérarchique des caractéristiques discriminantes, éliminant ainsi la nécessité d’une ingénierie manuelle complexe des descripteurs.

Un CNN est généralement composé de plusieurs types de couches principales :

- **Les couches convolutives**, qui appliquent des filtres (ou noyaux) glissants sur l’image d’entrée afin d’extraire des motifs locaux (bords, textures, formes simples), puis des représentations de plus haut niveau à mesure que l’on progresse dans les couches.
- **Les couches de pooling** (souvent max-pooling), qui réduisent les dimensions spatiales des représentations tout en conservant les informations essentielles, ce qui permet de diminuer la complexité computationnelle et de contrôler le surapprentissage.
- **Les couches entièrement connectées**, en fin de réseau, qui interprètent les caractéristiques extraites pour produire une prédiction finale (comme une classification).

L’efficacité des CNN repose sur plusieurs atouts majeurs :

- **La réduction du besoin d’extraction manuelle de caractéristiques** : les filtres convolutifs apprennent directement, à partir des données, les caractéristiques les plus pertinentes pour la tâche à accomplir.
- **La capacité à apprendre des invariances spatiales** : les CNN peuvent reconnaître un motif indépendamment de sa position dans l’image, ce qui est crucial pour les tâches de reconnaissance d’objets ou de lésions.
- **L’adaptabilité aux grands volumes d’images** : les CNN tirent profit des grandes bases de données pour affiner leur apprentissage et améliorer leur capacité de généralisation.

Comparés aux méthodes classiques comme les *Artificial Neural Networks* (ANN) ou les *k-Nearest Neighbors* (KNN), les CNN se distinguent par :

- **leur robustesse aux variations d’échelle, de rotation et de bruit,**
- **leur capacité à modéliser des structures complexes de données visuelles,**
- **leur efficacité dans les environnements de classification multiclassés ou multivariés.**

Transfert Learning

Le *Transfert Learning* (ou apprentissage par transfert) est une technique d’apprentissage automatique qui consiste à exploiter les connaissances acquises par un modèle lors de

l'entraînement sur une tâche source, généralement très généraliste (comme la classification d'images naturelles dans ImageNet), pour les réutiliser sur une tâche cible plus spécifique (comme la détection de maladies dermatologiques).

Cette approche s'est imposée dans le domaine de la santé numérique, notamment en raison des défis liés à l'obtention de grandes quantités de données annotées, souvent coûteuses et rares en milieu médical. Elle présente plusieurs avantages significatifs :

- **Réduction des besoins en données annotées** : le modèle ayant déjà appris à extraire des caractéristiques visuelles génériques (textures, formes, bords), il nécessite moins d'exemples pour se spécialiser dans une nouvelle tâche.
- **Accélération de la convergence** : le processus d'apprentissage est plus rapide car les poids initiaux du réseau sont déjà optimisés sur une base riche et diversifiée.
- **Amélioration de la généralisation** : même en présence de peu de données médicales, le modèle est capable de maintenir des performances élevées, en évitant le surapprentissage.

Dans le cadre de la classification d'images médicales, les architectures CNN pré-entraînées (comme ResNet, VGG ou EfficientNet) sont souvent utilisées comme extracteurs de caractéristiques. Leurs couches initiales, sensibles aux formes de bas niveau, sont généralement conservées (gelées), tandis que les couches supérieures sont réentraînées sur le nouveau jeu de données.

Les travaux de recherche récents montrent que cette approche surpasse les méthodes classiques entraînées à partir de zéro, tant en termes de précision que de robustesse. Le *Transfer Learning* permet ainsi de tirer pleinement parti de l'intelligence artificielle même dans des contextes où les ressources en données et en annotation sont limitées, comme c'est souvent le cas en dermatologie. Plusieurs architectures ont été évaluées :

- **ResNet-152** : A atteint une AUC allant jusqu'à **96,61%** et une précision de 90,4% dans la détection de mélanome sur la bases ISIC [25].
- **DenseNet-201** : A atteint une AUC moyenne de **98,16 %** dans la multi classification avec les dataset HAM10000 and PH2 [25]
- **Inception v3** : A obtenu une AUC allant jusqu'à **97,80 %** dans la multi classification avec les dataset HAM10000 and PH2 [25]
- **LeNet** : a atteint une précision de **95,86 %** sur le dataset ISIC [25].
- **LightNet** : Optimisé pour l'efficacité, avec une précision rapportée de **81,6%** sur ISIC2016 [25].
- **VGG-16** : Modèle plus ancien, présentant des performances inférieures (**78 %** de précision sur le dataset ISIC [25]).

Les architectures comme ResNet, DenseNet ou Inception intègrent des innovations comme les connexions résiduelles ou les blocs densément connectés, améliorant la profondeur du réseau sans surapprentissage.

Comparaison du transfert learning avec un CNN sans transfert une comparaison des performances de deux versions du modèle ResNet-50 pour la classification des lésions cutanées. [26] Le premier modèle a été entraîné depuis zéro, avec des poids initialisés aléatoirement, tandis que le second a été pré-entraîné sur ImageNet, puis ajusté (fine-tuning) sur un ensemble d'images dermatologiques, a montré que le modèle entraîné sans transfert n'a atteint qu'une précision de 79,13% pour la détection du mélanome, contre 93,89% pour le modèle utilisant le transfert learning. En plus de ses performances inférieures, le modèle sans transfert a présenté un surapprentissage plus marqué et a nécessité un temps d'entraînement plus long pour converger.

TABLE 2.1 – Comparaison des méthodes pour la détection des lésions cutanées avec références

Méthode	Avantages	Limites	Précision/AUC	Cas d'usage typique
Méthodes classiques (HOG, Viola-Jones, DPM)	Simplicité Rapidité	Features manuelles Sensible au bruit	–	Études comparatives
ANN	Modèle non-linéaire	Features manuelles	86,6%[23] à 97.09%[24]	Petits datasets
SOM	Clustering Visualisation	Non supervisé	93,15% jusqu'à 98,3% de précision [25]	Analyse exploratoire
CNN sans TL	Features automatiques	Besoin données	79% [26]	Cas spécifiques
CNN + TL (ResNet, DenseNet)	Meilleure généralisation Performance élevée	Complexe	ResNet-152 : AUC 96,61% précision 90,4% [25]. DenseNet-201 : AUC 98,16 % [25] Inception v3 : AUC 97,80 % [25] LeNet : précision 95,86 % [25]. LightNet :précision 81,6% [25]. VGG-16 : (78 % précision [25].	Applications cliniques

Transfert learning : une solution optimale d'après le tableau 2.1, Pour exploiter les performances des CNN tout en limitant les besoins en données, la meilleure approche est le transfert learning . il consiste à réutiliser un modèle pré-entraîné (comme ResNet ou DenseNet) sur un large corpus d'images , puis à adapter les couches finales au domaine médical. Les étapes suivies sont :

1. Chargement du modèle pré-entraîné .
2. Remplacement des couches de sortie par des couches spécifiques à notre classification (binaire ou multiclasse).
3. Gel des premières couches pour conserver les caractéristiques générales.
4. Réentraînement des couches supérieures avec nos données médicales.
5. Application de techniques d'augmentation (flip, rotation, zoom, contraste).

2.7 Conclusion

Ce chapitre a permis d'établir les fondations technologiques du système DermAI-Detect en analysant de manière comparative les choix essentiels à sa conception. Plusieurs éléments clés ont été déterminants :

Base de données : La base ISIC 2019 a été retenue pour sa richesse, sa diversité et sa structuration, avec 25 331 images réparties en huit classes. Elle permet de couvrir un spectre large de lésions bénignes et malignes, assurant ainsi un bon entraînement des modèles, tout en soulignant l'importance d'un équilibrage des classes et d'une validation sur des données hétérogènes.

Carte embarquée : Le Raspberry Pi 4 couplé à la Camera Module 3 s'est imposé comme le meilleur compromis entre performance, coût, consommation énergétique et portabilité, permettant une inférence locale et rapide même dans des environnements à ressources limitées.

Modèles d'IA : Après évaluation de différentes approches (méthodes classiques, ANN, SOM), les réseaux neuronaux convolutifs (CNN) avec transfert learning se sont révélés les plus efficaces. En particulier, des architectures comme ResNet-152 et DenseNet-201 offrent une grande précision grâce à l'apprentissage hiérarchique de caractéristiques visuelles complexes.

3 Chapitre 3 :Solution,Conception et Déploiement du Système Proposé

3.1 Introduction

Ce chapitre décrit en détail la solution technologique développée dans le cadre de ce travail, à savoir DermAI-Detect, un système intelligent destiné à assister le diagnostic du cancer de la peau. Face aux limites des méthodes cliniques traditionnelles, notamment en matière de détection précoce du mélanome, ce projet propose une alternative fondée sur l'intelligence artificielle, capable d'analyser automatiquement des images dermatologiques et de classer les lésions cutanées avec un haut degré de précision.

La conception du système repose sur une approche modulaire et évolutive, intégrant des techniques avancées de traitement d'images et d'apprentissage profond. Ce chapitre présente successivement l'architecture globale du système, ainsi que les étapes clés de son développement, de son entraînement à son déploiement. L'objectif est de démontrer comment DermAI-Detect peut s'adapter à différents contextes cliniques, y compris dans des environnements à ressources limitées, tout en respectant les exigences de performance, d'interprétabilité et d'éthique médicale.

3.2 Architecture globale du système

La solution *DermAI-Detect* s'appuie sur une architecture modulaire composée de quatre grandes parties présenté dans le diagramme de la figure 3.1 :




FIGURE 3.1 – Schéma global de l'architecture de *DermAI-Detect*.

- **Pipeline de traitement de données** : conception d'un pipeline dédié à la constitution, au nettoyage et à la préparation du jeu de données utilisé pour l'entraînement des modèles.
- **Module de classification** : développement de deux modèles AI pour la classification des lésions cutanées. Le premier est un modèle de classification binaire permettant de déterminer si une tumeur est bénigne ou maligne. Le second est un modèle de classification multiclasse capable d'identifier précisément le type de lésion.
- **Modèle de collecte automatisée de nouvelles données** : développement d'un troisième modèle d'AI destiné à détecter la présence de peau et à capturer automatiquement la zone à analyser.
- **Application** : déploiement du système au sein de deux applications (mobile et desktop), l'application desktop dédiée à l'utilisation professionnelle par un médecin et l'application mobile pour utilisation personnelle au cas de diagnostic rapide.

3.3 Pipeline de traitement de données

le choix dans cette partie dépend fortement du modèle utilisé dans le module de classification. La préparation des données visuelles est une étape essentielle dans toute chaîne de traitement d'image, notamment lorsqu'il s'agit de détection d'anomalies ou d'extraction de caractéristiques. Dans ce travail, nous avons mis en œuvre une série de techniques classiques et éprouvées pour isoler efficacement l'objet d'intérêt à partir d'une image en

couleur. Le processus peut être structuré en cinq étapes principales :conversion de l'espace colorimétrique, suppression de l'arrière-plan, seuillage adaptatif, nettoyage morphologique du masque,et application finale du masque sur l'image. Chacune de ces étapes est détaillée dans les sections suivantes.

3.3.1 Conversion de l'espace colorimétrique RGB vers HSV

La première transformation consiste à convertir l'image de l'espace colorimétrique RGB (*Red, Green, Blue*) vers HSV (*Hue, Saturation, Value*). Contrairement à l'espace RGB, l'espace HSV sépare l'information chromatique(teinte et saturation) de l'intensité lumineuse (valeur), ce qui le rend plus adapté aux opérations de seuillage basées sur la luminosité. Cette séparation permet une meilleure détection des pixels correspondant à l'arrière-plan sombre, souvent caractérisé par de faibles valeurs dans le canal .

3.3.2 Suppression de l'arrière-plan par seuillage dans l'espace HSV

L'arrière-plan noir est supprimé à l'aide d'un seuillage binaire basé sur une plage de valeurs dans l'espace HSV. Le seuillage par plage (ou *in-range thresholding*) permet d'extraire les pixels appartenant à une région spécifique de l'espace de couleur. En fixant un intervalle étroit autour de valeurs faibles de luminosité, les pixels sombres correspondant à l'arrière-plan sont isolés, produisant un masque binaire inversé servant à filtrer l'image initiale.




FIGURE 3.2 – Images comparatives avant et après suppression du fond noir

comme montre la figure 3.2 ce traitement supprime uniquement le fond noir présent sur les images prise avec un dermatoscope circulaire. Cette méthode repose sur la robustesse du canal pour distinguer les variations de luminosité

3.3.3 Segmentation via seuillage d'Otsu

L'image sans fond est ensuite convertie en niveaux de gris afin de procéder à une segmentation basée sur l'intensité. La méthode de seuillage d'Otsu [27] est utilisée pour séparer automatiquement les objets d'intérêt du fond restant. Cette méthode calcule un seuil optimal qui minimise la variance intra-classe dans l'histogramme des niveaux de gris. Elle est particulièrement efficace lorsque l'histogramme de l'image présente une répartition bimodale, caractéristique des images contrastées après suppression de l'arrière-plan.



(a) Originale vs après traitement

(b) originale vs après traitement

FIGURE 3.3 – Images comparatives avant et après segmentation otsu

Le résultat montré dans la figure 3.3 est un masque binaire brut qui peut contenir du bruit ou des artefacts, nécessitant des opérations de nettoyage supplémentaires.

3.3.4 Post-traitement morphologique du masque de segmentation

Le masque brut est affiné par des opérations morphologiques classiques : l'ouverture et la fermeture. L'ouverture, qui consiste en une érosion suivie d'une dilatation, permet d'éliminer les petits objets ou bruits isolés. La fermeture (dilatation suivie d'érosion) comble les trous internes aux objets segmentés et renforce la cohésion des régions détectées.

Ces opérations sont fondamentales dans le traitement d'image morphologique, car elles assurent une meilleure cohérence topologique du masque de segmentation, améliorant ainsi la qualité de l'extraction de la région d'intérêt.

3.3.5 Application finale du masque sur l'image filtrée

Enfin, le masque morphologiquement nettoyé est appliqué à l'image initiale (sans arrière-plan) afin d'extraire uniquement les pixels pertinents correspondant à l'objet d'étude.




FIGURE 3.4 – Images comparatives avant et après application du masque finale

Cette opération de masquage binaire permet de produire ce résultat final présenté dans la figure3.4 ne contenant que l'objet segmenté,prêt à être exploité pour des étapes ultérieures de la classification.

L'application de cette chaîne de traitement assure une segmentation robuste, particulièrement adaptée aux images présentant des objets bien délimités sur fond sombre.

3.4 Module de classification

Le module de classification constitue le cœur du système *DermAI-Detect*, chargé de distinguer les différentes catégories d'anomalies cutanées à partir d'images dermatologiques. Le choix de la méthode d'intelligence artificielle à adopter a nécessité une étude comparative approfondie des principales approches de classification, tant classiques que modernes. L'objectif était de sélectionner la solution offrant le meilleur compromis entre précision, capacité de généralisation, complexité de mise en œuvre et coût computationnel.

Choix final Au regard de l'ensemble des éléments analysés, le choix final s'est porté sur une approche fondée sur les **réseaux de neurones convolutifs avec transfert learning**,en particulier l'architectures pré-entraînée *ResNet-152*, pour les deux tâches de classification.




FIGURE 3.5 – architecture du module de classification

Le schéma de la figure 3.5 illustre le fonctionnement du système de classification d'image dans *DermAI*, organisé autour de deux modèles distincts qui sont activés selon le choix explicite de l'utilisateur. Lorsqu'une image est fournie en entrée, l'utilisateur peut opter soit pour une **classification binaire**, soit pour une **classification multiclass**, en fonction du contexte clinique ou des besoins d'analyse. Pour la classification binaire, les classes **MEL**, **BCC**, **AK** et **SCC** sont regroupées sous l'étiquette *malin*, tandis que les autres sont considérées comme *benignes*. Le modèle binaire permet de déterminer si une lésion est *benigne* ou *maligne*, fournissant une réponse rapide utile pour le tri initial. En revanche, le modèle multiclass permet une analyse plus fine en classant la lésion parmi huit catégories dermatologiques standards : *MEL* (mélanome), *NV* (naevus mélanocytaire), *BCC* (carcinome basocellulaire), *AK* (kératose actinique), *BKL* (lésion kératosique bénigne), *DF* (dermatofibrome), *VASC* (lésion vasculaire) et *SCC* (carcinome épidermoïde). Cette modularité du diagnostic, fondée sur un choix utilisateur, confère à *DermAI* une grande souplesse d'utilisation, rendant le système adapté aussi bien à une utilisation en milieu clinique qu'à des applications de recherche ou de formation.

- **Classification binaire** : pour distinguer les lésions bénignes des malignes.
- **Classification multiclass** : pour identifier précisément le type de lésion cutanée.

3.4.1 Architecture des modèles

Dans ce travail, nous avons conçu deux modèles de classification. Les deux modèles partagent la même architecture de base, avec uniquement la couche de sortie qui diffère selon le type de classification.

Transfert d'apprentissage avec ResNet152

La partie convolutive de notre architecture repose sur le modèle **ResNet152**, préentraîné sur le dataset ImageNet. Ce réseau profond comporte 152 couches et est réputé pour sa capacité à extraire des caractéristiques complexes grâce à ses blocs résiduels qui facilitent l'apprentissage en profondeur.

Nous avons chargé ce modèle avec l'option `include_top=False`, ce qui permet de supprimer la couche de classification originale du modèle ImageNet. L'entrée attendue par le modèle est une image de taille $256 \times 256 \times 3$.

Gel partiel des couches : afin de profiter des caractéristiques générales déjà apprises, nous avons gelé les couches initiales de ResNet152. Seules les **50 dernières couches** ont été rendues entraînaibles, ce qui permet d'adapter le modèle à notre tâche spécifique sans réapprendre des structures de bas niveau (contours, textures, etc.).

Couches personnalisées (tête du modèle)

Une fois les caractéristiques extraites par ResNet152, nous avons ajouté plusieurs couches denses pour effectuer la classification. Chaque couche a un rôle précis que nous détaillons dans ce schéma :




FIGURE 3.6 – Architecture commune utilisée pour la classification binaire et multiclasse

1. **GlobalAveragePooling2D** : cette couche effectue une moyenne globale sur chaque carte de caractéristiques. elle réduit fortement la dimensionnalité tout en conservant les informations les plus importantes. Elle rend le modèle plus robuste à la translation et réduit le nombre de paramètres.
2. **BatchNormalization** : elle standardise les activations de la couche précédente en temps réel lors de l'entraînement. Cela permet d'accélérer la convergence, de réduire le risque d'explosions de gradients, et d'améliorer la stabilité générale du modèle.
3. **Dense(512, activation='ReLU')** : cette couche entièrement connectée transforme les caractéristiques extraites en représentations plus abstraites. Elle contient 512 neurones avec l'activation ReLU (Rectified Linear Unit), qui introduit de la non-linéarité.
4. **Dropout(0.3)** : cette couche désactive aléatoirement 30% des neurones à chaque itération d'entraînement. Elle agit comme une régularisation et permet de limiter le

surapprentissage (*overfitting*) du modèle.

5. **Dense(256, activation='ReLU')** : une seconde couche dense plus compacte qui affine davantage les représentations apprises.
6. **Dropout(0.3)** : une nouvelle couche de régularisation identique à la précédente, pour renforcer la robustesse.
7. **Sortie (classification)** :
 - **Pour la classification binaire** : une couche **Dense(1)** avec une activation **sigmoid**. Elle retourne une probabilité entre 0 et 1 indiquant si l'image est bénigne ou maligne.
 - **Pour la classification multiclasse** : une couche **Dense(8)** avec une activation **softmax**

3.4.2 Augmentation de Données

L'augmentation de données est une technique essentielle pour améliorer la généralisation des réseaux de neurones, particulièrement dans les contextes à faible volume de données. Outre les transformations géométriques classiques(flips, rotations, etc) des méthodes plus récentes telles que **MixUp** et **CutMix** ont été introduites afin de générer des exemples synthétiques plus informatifs et régulariser les modèles d'apprentissage profond.

Avant l'application de méthodes de mélange, des transformations d'images classiques sont employées comme présente la figure 3.7 :



FIGURE 3.7 – architecture du module de classification

- **Symétries aléatoires (Flip)** : retournement horizontal ou vertical pour augmenter la variabilité spatiale.
- **Rotations multiples de 90 degrés** : introduisent une invariance rotationnelle sans altérer la structure des objets.
- **Altérations photométriques** : ajustements aléatoires de la luminosité et du contraste simulant des variations d'éclairage.

MixUp : Mélange Linéaire d'Exemples

MixUp, [28], est une méthode d'augmentation qui génère de nouveaux exemples d'entraînement par interpolation linéaire entre deux paires (image, étiquette). Données deux images $\mathbf{x}_i$ et $\mathbf{x}_j$ et leurs labels associés $\mathbf{y}_i$ et $\mathbf{y}_j$, un nouvel échantillon est construit comme suit :

$$\tilde{\mathbf{x}} = \lambda \mathbf{x}_i + (1 - \lambda) \mathbf{x}_j, \quad \tilde{\mathbf{y}} = \lambda \mathbf{y}_i + (1 - \lambda) \mathbf{y}_j \quad (3.1)$$

où $\lambda \sim \text{Beta}(\alpha, \alpha)$ est un coefficient de mélange.




FIGURE 3.8 – Résultat de l’algorithme Mixup sur deux images d’entrée

La figure 3.8 illustre un exemple de la technique MixUp, où deux images dermatologiques sont combinées de manière linéaire selon un coefficient λ aléatoire. L’image synthétique résultante est une interpolation des deux images sources, et son étiquette correspondante est également une combinaison pondérée de leurs étiquettes respectives, ici représentée par le vecteur $[0.73, 0.27]$. Cette approche permet d’introduire une plus grande variabilité dans les données d’entraînement, favorisant ainsi une meilleure généralisation du modèle et réduisant le risque de surapprentissage face aux caractéristiques spécifiques des lésions.

CutMix : Substitution Régionale d’Images

CutMix, [29] remplace une région rectangulaire d’une image par un extrait spatial d’une autre image de la même base, en ajustant l’étiquette proportionnellement à la surface remplacée :

$$\tilde{\mathbf{x}} = \mathbf{x}_i \odot \mathbf{M} + \mathbf{x}_j \odot (1 - \mathbf{M}), \quad \tilde{\mathbf{y}} = \lambda \mathbf{y}_i + (1 - \lambda) \mathbf{y}_j \quad (3.2)$$

où $\mathbf{M}$ est un masque binaire et λ est ajusté selon la surface de recouvrement. Cette technique permet de conserver une structure visuelle réaliste tout en diversifiant le signal supervisé, ce qui améliore la robustesse du modèle.



FIGURE 3.9 – Résultat de l’algorithme CutMix sur deux images d’entrée

La figure 3.9 présente un exemple concret de la méthode CutMix appliquée à des images de lésions cutanées. L’objectif est d’encourager le modèle à apprendre à partir d’exemples plus variés, en l’exposant à des compositions inhabituelles mais représentatives des classes originales. Les étiquettes sont ajustées proportionnellement à la surface occupée par chaque image dans la composition finale, comme l’indique ici le vecteur d’étiquettes $[0.59, 0.41]$. Cette stratégie favorise une meilleure généralisation en limitant le surapprentissage sur des motifs spécifiques, tout en améliorant la robustesse du classificateur face à la variabilité des images dermatologiques.

Validation empirique des techniques d’augmentation

L’étude de NUGROHO, ARDIYANTO et NUGROHO [30] démontre empiriquement l’impact significatif de l’augmentation de données sur la classification des lésions pigmentées. En utilisant le jeu de données *ISIC-2019*, les auteurs ont appliqué un ensemble d’augmentations pour équilibrer les huit classes de maladies dermatologiques. Trois architectures préentraînées (Inception-v3, DenseNet-201 et Xception) ont été évaluées.

Résultats clés : l’augmentation a permis une hausse spectaculaire des performances sur les métriques cliniques :

TABLE 3.1 – Performance des modèles avec et sans augmentation [30]

Modèle	SEN (%)	SPE (%)	PREC (%)	ACC (%)	F1 (%)	AUC
<i>Sans augmentation</i>						
Inception-v3	55.50	90.40	65.06	55.50	54.10	0.50
DenseNet-201	52.75	89.41	64.06	52.75	49.29	0.50
Xception	55.13	64.97	64.71	55.13	52.22	0.50
<i>Avec augmentation</i>						
Inception-v3	88.63	98.23	88.53	88.63	88.53	0.94
DenseNet-201	84.00	97.40	84.60	84.00	83.86	0.90
Xception	81.75	96.98	81.78	81.75	81.69	0.89

Ces résultats du tableau 3.1 confirment que l’augmentation, lorsqu’elle est correctement appliquée, permet :

- d’atténuer l’effet des classes déséquilibrées.
- d’augmenter significativement la sensibilité (SEN), cruciale en diagnostic médical.
- de réduire le surapprentissage par meilleure généralisation.

Ainsi, l’intégration de méthodes telles que MixUp et CutMix dans un pipeline d’apprentissage profond représente une stratégie à la fois simple et très efficace pour améliorer la robustesse d’un modèle, notamment en imagerie médicale.

3.4.3 Compilation et réglages d’entraînement

Une fois l’architecture du modèle définie, plusieurs étapes essentielles sont nécessaires avant l’entraînement, notamment la gestion du déséquilibre des classes, la configuration de la fonction de perte, le choix des métriques, ainsi que les stratégies d’optimisation et d’arrêt anticipé. Ces étapes visent à maximiser la performance tout en évitant le surapprentissage.

Instanciation du modèle

Le modèle final est construit en reliant l’entrée du réseau préentraîné (ResNet152 tronqué) à la tête personnalisée (les couches denses décrites précédemment). Il s’agit donc d’un modèle de type “feature extractor + classificateur dense”.

Prise en compte du déséquilibre des classes

Le jeu de données utilisé présente un déséquilibre marqué entre les classes (notamment entre lésions bénignes et malignes). Pour compenser cette distribution inégale, des poids de classes sont calculés de manière automatique selon l’inverse de leur fréquence. Ces poids sont ensuite appliqués lors de l’entraînement pour accorder une plus grande importance aux classes minoritaires. Cela permet d’améliorer le rappel (sensibilité) de la classe maligne, souvent sous-représentée mais cruciale en contexte médical.

Fonction de perte et métriques

Pour la tâche de classification binaire, la fonction de perte choisie est l'entropie croisée binaire (*binary crossentropy*). Cette fonction est adaptée aux sorties de type probabiliste comprises entre 0 et 1 (activation sigmoïde). Dans le cas de la classification multiclasse, on utilise plutôt l'entropie croisée catégorielle (*categorical crossentropy*), en combinaison avec une activation *softmax*, qui permet de modéliser la distribution de probabilité sur plusieurs classes exclusives.

Le modèle est évalué durant l'entraînement selon plusieurs métriques complémentaires :

- **Exactitude (Accuracy)** : proportion globale de prédictions correctes.
- **AUC (Area Under the Curve)** : mesure la capacité du modèle à séparer correctement les classes positives et négatives. Elle est particulièrement pertinente en cas de classes déséquilibrées.
- **Rappel (Recall)** : proportion de vrais positifs détectés sur l'ensemble des cas réellement positifs. En médecine, le rappel est essentiel car il reflète la capacité à ne pas rater un cas dangereux.
- **Précision (Precision)** : proportion de cas prédits positifs qui sont effectivement positifs. Elle permet d'évaluer la fiabilité des alertes émises par le modèle.

Optimisation de l'apprentissage

Le modèle est entraîné avec l'optimiseur **Adam**, qui combine les avantages d'Adagrad et RMSProp. Il ajuste automatiquement le taux d'apprentissage de chaque paramètre et favorise une convergence plus rapide et plus stable. Un faible taux d'apprentissage initial est choisi afin de permettre un raffinement progressif des poids.

Stratégies de régularisation dynamique

Deux techniques complémentaires sont utilisées pour encadrer la phase d'entraînement :

Arrêt anticipé (EarlyStopping) Cette méthode interrompt automatiquement l'apprentissage si la performance du modèle sur l'ensemble de validation ne s'améliore plus après un certain nombre d'itérations. Elle permet d'éviter un surapprentissage (overfitting) et garantit que les meilleurs poids sont conservés. Le critère de surveillance principal est l'AUC de validation, avec une patience définie pour autoriser de petites stagnations temporaires.

Réduction adaptative du taux d'apprentissage (ReduceLROnPlateau) Lorsque la métrique AUC de validation cesse de progresser, le taux d'apprentissage est réduit de

moitié. Cela permet au modèle de continuer à s'améliorer lentement en affûtant ses ajustements. Un seuil minimal est imposé pour éviter que le taux d'apprentissage ne devienne négligeable. Un temps de récupération ("cooldown") est également défini entre deux réductions successives.

Ces choix de compilation et de réglages dynamiques constituent un équilibre entre performance, stabilité et robustesse. Ils sont particulièrement adaptés au domaine médical, où l'erreur de détection peut avoir des conséquences graves, et où la classe d'intérêt est souvent minoritaire.

3.5 Modèle de collecte automatisée de nouvelles données

Dans le cadre de ce travail, un module de collecte automatisée a été mis en place dans le but d'assister la caméra embarquée à capturer uniquement des images pertinentes contenant de la peau. Ce filtrage préliminaire permet d'optimiser l'acquisition des données tout en réduisant le stockage d'images non exploitables pour l'analyse dermatologique.

3.5.1 Objectif et principe

En vision par ordinateur, la détection d'objets est une tâche consistant à localiser et classer des objets dans une image. Parmi les approches modernes les plus performantes figure l'algorithme **YOLO (You Only Look Once)**, qui repose sur un modèle de deep learning capable de détecter plusieurs objets en un seul passage dans l'image. YOLO offre un excellent compromis entre précision et rapidité, ce qui le rend particulièrement adapté aux systèmes temps réel ou embarqués.

Dans notre cas, nous exploitons cette capacité pour concevoir un module intelligent capable d'identifier automatiquement si une image capturée contient de la peau humaine ou non. Ce modèle est intégré dans la chaîne de collecte afin de n'enregistrer que les images jugées pertinentes pour l'analyse dermatologique.

3.5.2 Architecture du modèle

Le modèle utilisé repose sur l'architecture **YOLOv8 Nano**, une version compacte et optimisée de YOLO, spécifiquement conçue pour fonctionner dans des environnements à ressources limitées (tels que les systèmes embarqués). Il a été entraîné pour effectuer une détection binaire avec deux classes :

- **Classe 0** : image contenant de la peau
- **Classe 1** : image ne contenant pas de peau

L'entraînement s'est appuyé sur un jeu de données combinant :

- des images issues de la base dermatologique HAM1000 pour la classe *peau*,
- des images générales provenant de la base COCO 2025 pour la classe *non-peau*.

3.5.3 Etapes du développement

Le processus global de collecte automatisée suit les étapes suivantes :

1. Prétraitement des images d'entrée
2. Génération des annotations au format YOLO
3. Entraînement du modèle YOLOv8 Nano sur les données binaires
4. Évaluation à l'aide des métriques standards (précision, rappel, mAP)

3.5.4 Avantages

L'intégration de ce module permet de :

- Réduire considérablement le bruit dans les données collectées
- Alléger la charge de traitement des étapes suivantes
- Accélérer la constitution de jeux de données pertinents pour l'entraînement des modèles de classification

3.6 Intégration des modèles dans deux systèmes applicatifs

3.6.1 Introduction

Les modèles de classification et le pipeline du traitement développés dans ce projet ont été intégrés dans deux systèmes complémentaires. Le premier est une application Desktop connectée à un Raspberry Pi et une caméra pour la capture d'images en temps réel. Le second est une application mobile destinée à une utilisation autonome et portable.

3.6.2 Architecture générale

L'architecture de l'intégration repose sur deux volets :

- **Système 1** : Raspberry Pi avec caméra → Application Desktop
- **Système 2** : Application mobile autonome

Chaque système utilise les mêmes modèles de classification et un pipeline de prétraitement similaire, adapté aux contraintes spécifiques de la plateforme cible.

3.6.3 Intégration dans le système Desktop avec Raspberry Pi

Objectif

Ce système a pour but de capturer l'image en temps réel via une caméra connectée à un Raspberry Pi, de l'envoyer à une application Desktop, d'effectuer la segmentation de la lésion, puis de lancer la classification locale.

Technologies utilisées




FIGURE 3.10 – Schéma simplifié de l'architecture du système

la figure 3.10 montres les éléments principales qui composent le système .

- Raspberry Pi OS 64bits (ou tout autre système léger)
- camera compatible avec Raspberry Pi CSI2
- Application Desktop

l'envoi des images en temps réel entre le Raspberry et l'application Desktop se fait via un streaming en session ssh



FIGURE 3.11 – image du montage réel

la figure 3.11 montre l'image du montage Raspberry-camera .

Architecture du Système

Le flux de traitement suit les étapes suivantes de la figure 3.12 :




FIGURE 3.12 – Schéma simplifié de l'architecture du système

1. Capture d'image par la caméra via le Raspberry Pi
2. Transmission de l'image à l'application Desktop (via socket,ssh session)
3. Application des étapes de prétraitement : suppression du fond, segmentation
4. Classification à l'aide du modèle choisi (binaire ou multiclassés)
5. Affichage des résultats dans l'interface Desktop

Application desktop

Objectif de l'application

L'objectif principal de cette application est de fournir un outil ergonomique, fonctionnel et accessible permettant l'exploitation directe des modèles de classification développés au cours de ce projet. Conçue pour un usage par les professionnels de santé, elle propose trois fonctionnalités majeures : l'acquisition en temps réel d'images de lésions cutanées, l'analyse automatisée via des modèles d'intelligence artificielle pour la classification des lésions, et la gestion complète des données patients. Cette dernière inclut le suivi des cas cliniques, la génération de statistiques et l'enrichissement progressif d'une base de données dermoscopique. L'outil vise à faciliter le diagnostic préliminaire dans des environnements à ressources limitées où l'accès à un dermatologue peut s'avérer difficile, contribuant ainsi à une meilleure orientation des soins et à une détection plus précoce des affections cutanées.

Choix technologiques

Technologies utilisées :

- **Langage de programmation** : Python3
- **Interface graphique** : PyQt5
- **Bibliothèques de traitement d'image** : OpenCV.
- **Chargement et exécution des modèles** : TensorFlow (Keras).
- **Système d'exploitation cible** : Windows (extensible à Linux/Mac)

Architecture de l'application

L'application repose sur une architecture modulaire articulée autour de trois couches principales comme montre le diagramme de la figure 3.13 :

1. **Interface Utilisateur (UI)** : Gère l'interaction avec l'utilisateur. Elle permet de charger une image, de sélectionner un modèle de classification, et d'afficher les résultats de prédiction.
2. **Couche de traitement et de prédiction** : Assure le pipeline de traitement d'image (prétraitement,redimensionnement, normalisation, etc) le chargement des modèles d'IA et l'exécution des prédictions.
3. **Couche de gestion des données** : Gère la base de données locale pour le stockage, la mise à jour et la visualisation des informations liées aux patients et aux résultats.




FIGURE 3.13 – Schéma simplifié de l'architecture logicielle de l'application Desktop

Fonctionnalités implémentées


L'application intègre les fonctionnalités suivantes :

- Acquisition en temps réel d'images lésionnelles,assistée le modèle yolo de détection de zones cutanées.
- Prétraitement automatique des images avant classification.
- Classification binaire ou multiclasse des lésions à l'aide des modèles d'IA intégrés.
- Gestion des données patients : enregistrement, consultation et suivi longitudinal.
- Visualisation des statistiques cliniques (fréquences, types de lésions etc).
- Collecte automatisée des nouvelles images pour enrichir progressivement la base de données dermoscopique.


Interface utilisateur

Conçue pour être intuitive et accessible, l'interface utilisateur comprend :

- Une fenêtre principale présentant le menu général et les consignes d'utilisation.
- Un système de navigation par menu permettant d'accéder facilement aux différentes sections de l'application.
- Plusieurs pages dédiées aux fonctionnalités spécifiques (acquisition, prédiction,gestion des patients, etc).
- Une zone de résultats affichant la classe prédite ainsi qu'un indice de confiance associé.




(a) Menu de l'application



(b) Sélection de l'image



(c) Tableau de bord



(d) Jeu de données images

	id	nom	prenom	email	telephone	sexe	date_naissance	nombre_examens	resultat_global
1	1	aymen	regifg	qregfd	regfdgfd	Homme	2000-01-01 00:00:00	1	benigne
2	2	qef	qef	qef	qefdg	Homme	2000-01-01 00:00:00	1	benigne
3	3	sergfd	qefgfd	qefgfd	qregdfg	Homme	2000-01-01 00:00:00	2	benigne
4	4	dregfd	fdg	sergfd	qregfdg	Homme	2000-01-01 00:00:00	2	benigne
5	5	qregfd	qregfdg	qregfd	qregfd	Femme	2000-01-01 00:00:00	1	benigne
6	6	qregfd	qregfd	qregfd	qregfdg	Femme	2000-01-01 00:00:00	1	benigne
7	7	regfd	regfd	qregfd	qregfd	Femme	2000-01-01 00:00:00	1	Inconnu

(e) Base de données patients



(f) Fenêtre de diagnostic

FIGURE 3.14 – Captures d'écran de l'application

la figure 3.14 présentes les capture d'écrans des pages principales dans l'application ,




FIGURE 3.15 – Captures d’écran montrant la détection en temps réel via l’application

La figure 3.15 illustre le fonctionnement du module de collecte automatisée de nouvelles images au sein de l’application. Les captures présentées montrent que le modèle facilite de manière significative l’acquisition d’images en détectant automatiquement les zones de peau et les lésions cutanées.

Couche de traitement et de prédiction

La couche de traitement et de prédiction est chargée de l’ensemble des opérations nécessaires à l’analyse automatisée d’une image dermatologique, depuis sa préparation jusqu’à l’obtention du diagnostic. Elle débute par la prise en charge de l’image d’entrée, obtenue via la caméra ou la galerie de l’appareil, puis détecte la peau dans l’image ou la zone cutanée et lui applique une série d’étapes de prétraitement essentielles : redimensionnement aux dimensions requises par le modèle, normalisation des valeurs de pixels, et éventuellement segmentation de la lésion cutanée pour isoler la zone d’intérêt. Ces traitements visent à standardiser l’image et à optimiser la qualité des données fournies au modèle. L’image prétraitée est ensuite transmise aux modèles de classification selon le choix de l’utilisateur. Le modèle produit alors une prédiction de classe, correspondant au type de lésion cutanée identifiée, accompagnée d’un score de confiance et d’éventuelles métadonnées sur le traitement. Cette couche constitue ainsi le cœur décisionnel du système, en transformant une image brute en résultat médical exploitable, prêt à être affiché à l’utilisateur via l’interface graphique.

Couche de gestion des données

La couche de gestion des données repose sur l’utilisation de **TinyDB**, une base de données locale, non relationnelle, particulièrement adaptée aux environnements aux ressources limitées. Grâce à sa structure flexible et sa simplicité d’intégration, **TinyDB** permet de stocker les données sous forme de documents JSON, ce qui facilite la sérialisation et l’organisation des informations sans avoir recours à un schéma complexe.

Cette couche assure plusieurs fonctions essentielles au bon fonctionnement de l'application, notamment : l'**enregistrement** des résultats de classification, la **mise à jour** des données associées à un patient ou à une image, la **recherche** rapide d'entrées spécifiques, ainsi que l'**organisation** structurée des données pour leur visualisation et leur exploitation ultérieure. Elle garantit ainsi la **persistance locale des informations médicales**, tout en permettant un accès rapide et sécurisé, même hors connexion. Cette approche est idéale pour une gestion efficace de données sans dépendance à un serveur distant.

Défis rencontrés et solutions apportées

L'intégration des modèles dans une application graphique a soulevé plusieurs défis techniques, parmi lesquels :

- **Performance et temps de réponse** : certaines opérations lourdes ont été optimisées et exécutées dans des threads indépendants pour préserver la fluidité de l'interface.
- **Robustesse face aux erreurs** : un système de gestion des exceptions a été mis en place pour éviter les blocages dus à des entrées invalides ou des fichiers corrompus.
- **Amélioration de l'expérience utilisateur** : l'ajout de messages d'état, barres de progression et notifications a permis d'optimiser l'interaction avec l'utilisateur.
- Instabilité dans la qualité des images capturées par la camera du Raspberry
- Échecs occasionnels de segmentation sur des cas extrêmes (images floues, mal cadrées)

3.6.4 Intégration dans l'application mobile

Objectif

L'objectif de l'application mobile est de fournir un diagnostic rapide en permettant à l'utilisateur de capturer une photo ou de sélectionner une image depuis la galerie, de segmenter la lésion, puis de lancer la classification à partir de l'appareil mobile et visualiser le résultat.

Technologies utilisées

- Développement mobile (Flutter/dart pour Android)
- 2 modèles de classification TensorFlow Lite
- OpenCV pour le traitement pipeline

Architecture de l'application




FIGURE 3.16 – Schéma simplifié de l'architecture logicielle de l'application mobile


la figure 3.16 montres les différentes couches de l'application mobile :

- La couche d'interface graphique constitue la partie visible et interactive de l'application, permettant à l'utilisateur de naviguer intuitivement entre les différentes fonctionnalités. Conçue à l'aide du framework Flutter, cette interface est réactive, fluide et multiplateforme, s'adaptant aussi bien aux smartphones Android qu'iOS. Elle offre une expérience utilisateur claire et ergonomique, depuis l'accueil jusqu'à l'affichage des résultats de classification. Parmi les écrans principaux figurent : la page d'accueil, le module de capture ou de sélection d'image, l'affichage du résultat diagnostique, et la consultation de l'historique.
- La couche de traitement et de prédiction constitue le noyau intelligent du système, responsable de l'analyse des images et de l'inférence du diagnostic. Elle intègre à la fois le pipeline de traitement des données et le module de classification qui se compose de deux modèles pour la classification binaire (maligne/bénigne) et pour la classification multi-classe qui précise le type de la lésion selon les 8 classes de ISIC2019
- La couche de gestion de données de l'application repose sur l'utilisation de la bibliothèque hiveflutter, qui fournit une solution de stockage local rapide, légère et adaptée aux environnements mobiles. Cette couche assure la persistance des données essentielles de l'application, telles que l'historique des images analysées, les résultats de

classification. les données sont stockées sous forme de paires clé-valeur dans une base de données locale, sans nécessiter de serveur distant ou de moteur SQL complexe. L'intégration de hiveflutter permet en outre une synchronisation transparente avec l'interface utilisateur , ce qui garantit une mise à jour dynamique des données affichées. Cette approche assure un excellent compromis entre performance, simplicité et autonomie

Fonctionnement de l'application


L'application suit un enchaînement simple comme montres les captures de la figure 3.17 :




Menu principale



page du diagnostique



Historique des diagnostics



selection d'image

FIGURE 3.17 – captures de l'application mobile

L'application offre à l'utilisateur une interface intuitive lui permettant de fournir une image d'une lésion cutanée, soit en : capturant une photo en temps réel à l'aide de l'ap-

pareil photo du smartphone, soit en sélectionnant une image existante depuis la galerie multimédia de l'appareil.

Une fois l'image acquise, l'application déclenche une phase de prétraitement automatique, en passant l'image à la couche de traitement et de prédiction, cette couche utilise le pipeline de traitement de données pour la segmentation de la lésion cutanée afin d'isoler la zone d'intérêt et l'adaptation de l'image au format attendu par les modèles de tflite.

Après segmentation, l'image traitée est transmise au module de classification de la même couche, (modèles de classification binaire et multi-classes, préalablement entraînés pour identifier différentes classes de lésions cutanées). Enfin, le résultat du diagnostic est envoyé à la couche de gestion de données pour les enregistrer correctement et l'affichage. (catégorie prédite, score de confiance, éventuelles recommandations)

Optimisations

- Réduction de la taille du modèle
- Conversion vers un format mobile optimisé (TFLite)

Difficultés rencontrées

- Instabilité dans la qualité des images capturées par la camera
- Limitations des ressources (RAM, processeur, mémoire)
- Performances réduites des modèles sur certains téléphones peu puissants
- Échecs occasionnels de segmentation sur des cas extrêmes (images floues, mal cadrées)

3.7 Conclusion

L'intégration des modèles de classification dans une application multiplateforme — compatible avec les environnements desktop, Raspberry Pi et mobile — marque une avancée significative vers l'implémentation pratique d'un outil de diagnostic assisté par intelligence artificielle. Totalement autonome et fonctionnant sans connexion Internet, cette solution s'adapte aussi bien aux environnements médicaux contraints qu'à un usage personnel nomade. Elle offre ainsi une flexibilité d'utilisation essentielle pour répondre aux besoins de la médecine de terrain, en particulier dans les zones à ressources limitées. DermAI-Detect constitue une base technologique robuste pour le développement futur d'un système intelligent, évolutif et éthique, dédié au diagnostic précoce et à la prévention des cancers cutanés.

4 Chapitre 4 : Résultats et Discussion

4.1 Introduction

Ce chapitre expose les résultats expérimentaux obtenus lors de la mise en œuvre et de l'évaluation des différents modèles développés dans le cadre de ce projet. L'objectif principal est d'analyser dans quelle mesure ces modèles parviennent à remplir leurs fonctions respectives, à savoir la classification des lésions cutanées (binaire et multi-classes) ainsi que la détection d'images pertinentes à analyser dans un flux vidéo.

L'évaluation repose sur plusieurs jeux de données de référence, notamment ISIC 2019, ainsi que des données externes capturées dans des conditions réelles. Les performances des modèles sont quantifiées à l'aide d'indicateurs standards : précision, rappel, F1-score, courbe ROC-AUC, etc. Des visualisations telles que les matrices de confusion, les courbes d'apprentissage et les exemples de détection viennent appuyer l'interprétation des résultats.


Chaque modèle est d'abord présenté individuellement avec une analyse quantitative et qualitative de ses performances, suivie d'une mise en perspective par rapport à l'état de l'art. Enfin, une discussion critique synthétise les apports et les limites du système proposé, en soulignant les pistes d'amélioration futures.

4.2 Évaluation du modèle de classification binaire


Le modèle binaire a été entraîné pour distinguer entre lésions bénignes et malignes puis tester sur un dataset de validation de taille 224 images. Les performances ont été mesurées à l'aide de plusieurs métriques :

- **Exactitude (Accuracy)** : *89.29%*
- **AUC** : *94.91%*
- **Précision** : *89.00%*
- **Rappel (Recall)** : *89.00%*
- **F1-score** : *89.00*

Une matrice de confusion est présentée à la figure 4.1a pour illustrer la répartition des prédictions, avec le graph AUC présenté à la figure 4.1b.



(a) Matrice de confusion – classification binaire



(b) Courbe AUC – classification binaire

FIGURE 4.1 – Évaluation des performances pour la classification binaire.

TABLE 4.1 – Comparaison des performances entre notre modèle et ceux de la littérature

Modèle / Étude	Jeu de données	Méthodologie	Accuracy	Recall	AUC
Notre modèle	ISIC 2019	Resnet152 personnalisé	89.29%	89.00%	94.91%
LightNet (mobile) [31]	ISIC 2016	Réseau léger avec peu de paramètres, adapté aux applications mobiles	81.6%	14.9%	—
CNN (2 couches) [32]	170 images de lésions cutanées	Réseau CNN à deux couches convolutives simples	81%	81%	—
Region-based CNN + ResNet152[33]	ISIC (2742 images)	Extraction de la région d'intérêt par masque, classification avec ResNet152	90.4%	82%	—

Comparaison avec la littérature Les performances de notre modèle de classification binaire (bénin vs malin) ont été comparées à plusieurs approches issues de la littérature. Le tableau 4.1 résume cette comparaison. Notre modèle atteint une exactitude de **89.29 %** et une sensibilité de **89.00 %**, surpassant nettement les méthodes légères telles que LightNet (81.6 % d'accuracy et seulement 14.9 % de recall), ainsi qu'un CNN simple à deux couches (accuracy de 81 %). Par rapport à l'approche utilisant un Region-based CNN combiné à ResNet152, notre solution reste compétitive avec un recall supérieure (89 % contre 82 %) et

une AUC remarquable de **94.91 %**, soulignant sa capacité de discrimination. Ces résultats témoignent de l'équilibre atteint entre complexité, efficacité et performance, ce qui rend notre modèle particulièrement adapté à des environnements à ressources limitées tels que les applications mobiles ou embarquées.


TABLE 4.2 – Comparaison des performances entre notre modèle et ceux de l'étude I-IETA 2024 sur le jeu de données ISIC 2019 [34]

Méthode (Modèle)	Accuracy (%)	AUC	Recall (%)	Précision (%)	F1-score (%)
Notre modèle	89.29	0.949	89.00	89.00	89.00
AlexNet	92.56	0.923	94.77	92.04	93.38
ResNet-18	91.89	0.916	93.82	91.74	92.77
ResNet-50	92.98	0.927	95.08	92.46	93.75
MobileNet-v2	90.43	0.904	90.61	92.00	91.30
ShuffleNet	89.73	0.900	87.39	93.65	90.41
NASNet-Mobile	91.26	0.908	94.83	89.95	92.33
EfficientNetB0	91.20	0.908	94.20	90.33	92.22
VGG-19	91.79	0.911	97.54	88.76	92.94
GoogLeNet	80.96	0.789	97.16	75.50	84.97
SqueezeNet	80.89	0.787	98.36	74.96	85.08

Comparaison avec les méthodes du transfert learning Une comparaison autre comparaison avec une étude récente [34] menée en 2024 sur le jeu de données ISIC 2019 montre que notre modèle reste particulièrement compétitif (tableau 4.2). Bien que le modèle ResNet152 utilisé dans notre étude soit plus complexe et théoriquement plus performant que des architectures comme ResNet50 ou VGG19, son exactitude (accuracy) obtenue est légèrement inférieure. Cependant, cette différence est compensée par une AUC particulièrement élevée (94.91%), supérieure à celle de ResNet50 (92.7%) et VGG19 (91.1%). Ce résultat est particulièrement significatif dans un contexte médical, où l'AUC (Area Under the Curve) constitue un indicateur crucial, car il reflète la capacité du modèle à bien différencier les cas positifs des cas négatifs, indépendamment du seuil de décision choisi. Ainsi, notre approche privilégie la fiabilité de la détection, ce qui est essentiel pour des applications sensibles comme le dépistage du mélanome.




(a) Image de test (lésion maligne)



(b) Image de test (lésion maligne)



(c) Image de test (lésion maligne)



(d) Image de test (lésion bénigne)



(e) Image de test (lésion bénigne)



(f) Image de test (lésion maligne)

FIGURE 4.2 – Exemples de résultats de détections sur des images externes


La figure 4.2 illustre les résultats de classification obtenus sur des images externes à l'aide du modèle binaire intégré dans l'application desktop. Ces résultats montrent que, même en dehors du jeu de données d'entraînement, le modèle parvient à maintenir une précision satisfaisante et à effectuer des prédictions cohérentes.

4.3 Évaluation du modèle de classification multi-classes


Le second modèle permet de classer les lésions parmi plusieurs catégories : mélanome, grain de beauté, kératose, etc.

- **Exactitude (Accuracy)** : 92.17%
- **AUC** : 99.41%
- **Précision** : 94.52%
- **Rappel (Recall)** : 89.10%
- **F1-score** : 94.00%

Les résultats montrent de bonnes performances globales, bien que certaines confusions persistent notamment entre les mélanomes et les grains de beauté (cf. matrice de confusion)4.3a.



(a) Matrice de confusion – classification multi-classes



(b) Courbes AUC – classification multi-classes

FIGURE 4.3 – Visualisation des performances du modèle sur l'ensemble de test.

Observations :

- La classe “Mélanome” est souvent confondue avec “Grain de beauté”.

TABLE 4.3 – Comparaison des performances entre notre modèle et des études récentes sur la classification multiclassées avec le dataset ISIC

Étude	Accuracy	Précision	Recall	F1-score	AUC
modèle proposé	92.17 %	94.52 %	89.10 %	94.00 %	99.41 %
LeNet [35]	95.86 %	–	–	–	–
GoogleNet[36]	94.92 %	80.36 %	79.80 %	–	–
ConvNeXtV2 blocks with separable self-attention [37]	93.48 %	93.24 %	90.70 %	91.82 %	–

Comparaison avec la littérature Notre modèle a été comparé à plusieurs approches issues de la littérature utilisant le dataset ISIC en classification multiclassées. Comme le montre le tableau 4.3, bien que certains modèles présentent un accuracy globale légèrement plus élevée, notamment le modèle basé sur GoogleNet avec une accuracy de 94.92%, notre approche se distingue par une précision (94.52%) , rappel (89.10%) et un F1-score plus élevé (94.00%). et reste compétitive face à des modèles récents (ConvNeXtV2 blocks with separable self-attention) [37], en affichant un meilleure F1-score, bien que le rappel soit légèrement inférieur (89.10% contre 90.70%). En outre, l’AUC de 99.41% obtenue par notre modèle constitue un atout significatif, traduisant une excellente capacité discriminative entre les différentes classes de lésions cutanées. En comparaison avec les architectures avancées présentées le tableau de la figure 4.4 notre modèle montre des performances très compétitives. Il atteint une exactitude de 92.17%, une AUC exceptionnelle de 99.41% et un F1-score élevé de 94.00%. Ces valeurs dépassent celles obtenues par plusieurs modèles récents comme GcViT-small (accuracy : 92.13%, F1 : 89.13%) ou PiT-base (accuracy : 90.92%, F1 : 86.75%). Toutefois, notre modèle reste légèrement inférieur au modèle basé sur ConvNeXtV2 blocks avec separable self-attention, qui a atteint un F1-score de 91.82% et une accuracy de 93.48%, confirmant ainsi la supériorité de cette approche sur certains aspects.

TABLE 4.4 – Comparaison des performances de différents modèles sur la classification des lésions cutanées [37]

Modèle	Accuracy	Precision	Recall	F1-score
ResNetv2-50	0.8493	0.7809	0.7406	0.7571
Res2NeXt50	0.8798	0.8401	0.8144	0.8255
RexNet200	0.9040	0.8785	0.8596	0.8677
DenseNet121	0.8635	0.8126	0.7798	0.7932
Xception	0.8858	0.8677	0.8094	0.8345
GhostNetv2-100	0.8982	0.8615	0.8337	0.8440
MobileNetv3-large-0.75	0.8877	0.8442	0.8077	0.8249
EfficientNetv2-small	0.8858	0.8580	0.8148	0.8324
EfficientNet-B4	0.8827	0.8210	0.8035	0.8110
ConvNeXtV2-base	0.9163	0.8968	0.8794	0.8873
InceptionNeXt-base	0.8929	0.8616	0.8308	0.8444
ResMLP-24	0.8885	0.8786	0.8171	0.8449
PoolFormer-M36	0.8948	0.8596	0.8231	0.8374
XCiT-Small-Patch16	0.8785	0.8390	0.7921	0.8123
DeiT-base	0.9034	0.8887	0.8359	0.8588
ViT-base-patch16	0.8961	0.8656	0.8336	0.8483
Swinv-base	0.9179	0.9049	0.8757	0.8893
BeiTv2-base	0.9090	0.8775	0.8731	0.8741
MViTv2-base	0.9071	0.8883	0.8670	0.8736
MaxViT-base	0.9084	0.8783	0.8723	0.8737
RepViT-m2	0.9061	0.8792	0.8669	0.8713
PvTv2-B2	0.9029	0.8754	0.8399	0.8532
Tiny-ViT-21m	0.9082	0.8740	0.8724	0.8720
GcViT-small	0.9213	0.9127	0.8742	0.8913
PiT-base	0.9092	0.8952	0.8456	0.8675
ConvNeXtV2	0.9348	0.9324	0.9070	0.9182




FIGURE 4.4 – Captures de l'application mobile

La figure 4.4 présente des captures de la classification des images externes. On remarque que le modèle fait de bonnes prédictions en général, mais reste limité par la qualité des images en entrée, notamment en présence de flou, de mauvais éclairage ou de fond perturbateur. Ces facteurs peuvent nuire à la détection précise des lésions et entraîner des erreurs de classification.

4.4 Évaluation du modèle de détection

L'évaluation du modèle YOLOv8 Nano utilisé pour filtrer les images contenant de la peau repose sur plusieurs métriques standards de la détection d'objets. L'objectif est de mesurer la capacité du modèle à distinguer efficacement les images pertinentes pour l'analyse dermatologique, tout en limitant les faux positifs et les faux négatifs.


Métriques utilisées Les principales métriques utilisées dans l'évaluation du modèle sont :

- **Précision (Precision)** : proportion d'images correctement détectées comme contenant de la peau parmi toutes les images détectées positives.
- **Rappel (Recall)** : proportion d'images contenant effectivement de la peau qui ont été correctement identifiées par le modèle.
- **mAP@0.5** (mean Average Precision) : mesure la précision moyenne à un seuil d'Intersection over Union (IoU) de 0.5, standard pour la détection binaire.


Résultats expérimentaux Après entraînement sur la base HAM10000 (images dermatologiques) et COCO 2025 (images génériques), le modèle YOLO a été évalué sur un jeu de test indépendant, conçu pour simuler des conditions réelles de capture via caméra embarquée.

Les performances obtenues sont excellentes :

- **Précision** : 99.2%
- **Rappel** : 99.3%
- **mAP@0.5** : 99.0%



(a) Image 1



(b) Image 2

FIGURE 4.5 – résultat de l'entraînement

la figure 4.5 montre les résultats de l'entraînement. Ces résultats témoignent d'une très forte capacité de généralisation du modèle, avec un taux d'erreur inférieur à 1% sur l'ensemble des classes testées. Le modèle parvient non seulement à détecter efficacement la peau et les lésions, mais aussi à ignorer les éléments de fond non pertinents. Cela garantit une collecte d'images pertinente et fiable, tout en allégeant les traitements ultérieurs dans le pipeline.

Analyse qualitative Une inspection manuelle des résultats montre que les erreurs de détection concernent principalement :

- des images floues ou mal éclairées ;
- des zones de peau partiellement masquées ou très éloignées de la caméra ;
- des objets présentant des textures similaires à la peau.



FIGURE 4.6 – Exemples de détections réalisées par le modèle YOLOv8 Nano

d'après la figure 4.6 Dans l'ensemble, le modèle se montre robuste aux variations de contexte et de luminosité, ce qui est essentiel pour une application en environnement embarqué.

L'évaluation du modèle YOLOv8 Nano montre qu'il constitue un outil fiable pour l'assistance à la prise d'images dermatologiques. Son intégration dans la carte Raspberry améliore significativement la pertinence des données collectées, tout en respectant les contraintes de performance temps réel et de consommation de ressources.

4.5 Discussion

Dans cette section, nous analysons les résultats obtenus à travers les modèles proposés et discutons de leurs forces, de leurs faiblesses, ainsi que des pistes d'amélioration possibles. Les résultats expérimentaux montrent des performances globales satisfaisantes, mais certains aspects nécessitent des améliorations, notamment en ce qui concerne la classification multi-classes et la gestion de la qualité des images.

4.5.1 Analyse des résultats

Modèle de classification binaire

Les performances du modèle binaire révèlent un profil contrasté mais cohérent. L'**accuracy**, de **89.29%**, apparaît légèrement inférieure à celle rapportée dans certaines études antérieures, comme celle de Mahmoud et al. [34], où des modèles tels que ResNet-50 ou VGG-19 ont atteint plus de 92%. Cette différence peut s'expliquer par la nature du dataset initialement utilisé. En effet, celui-ci était fortement **déséquilibré**, avec une nette surreprésentation des lésions bénignes par rapport aux malignes (15,991 vs 9,340). Dans un tel contexte, un déséquilibre important peut nuire à la capacité du modèle à apprendre des représentations fiables pour la classe minoritaire, ce qui se traduit souvent par une **AUC plus faible**, reflet d'une mauvaise capacité de discrimination.

Pour pallier cela, une stratégie d'équilibrage simple a été appliquée, consistant à **dupliquer les images de la classe minoritaire** pour égaliser la distribution. Bien que cette méthode n'apporte pas de diversité nouvelle, elle a permis de **réduire le biais du modèle vers la classe majoritaire** et de forcer l'apprentissage de caractéristiques plus représentatives pour les deux classes. Ce rééquilibrage a eu pour effet notable une **augmentation significative de l'AUC**, qui atteint **94.49%**, surpassant les meilleurs résultats de l'étude comparative citée (ResNet-50 : 92.7%).

Cependant, cette amélioration de la capacité de discrimination a un coût. La duplication introduit une forme de redondance dans les données, ce qui peut **favoriser le surapprentissage** sur des exemples répétitifs. Ce phénomène contribue à une légère baisse de l'accuracy globale. Ainsi, on observe ici un **compromis classique entre AUC et accuracy**, typique des situations où l'on équilibre artificiellement un dataset fortement déséquilibré.

Modèle de classification multi-classes

Les résultats du modèle de classification multi-classes appliqué au dataset ISIC 2019 montrent des performances globalement très solides. La précision (94.52%) et le F1-score (94.00%) traduisent une capacité du modèle à bien distinguer les différentes classes, tandis qu'un AUC exceptionnellement élevé (99.41%) indique une excellente aptitude à la discrimination inter-classes, ce qui est crucial dans un contexte médical.

Effets de l'équilibrage du dataset : Le dataset initial présentait un fort déséquilibre, avec une surreprésentation des lésions bénignes de type NV (12 701 exemples), et une sous-représentation marquée des classes rares comme DF, VASC, ou SCC. Ce déséquilibre risquait d'entraîner une préférence du modèle pour les classes majoritaires, au détriment de la sensibilité pour les lésions plus rares.

Pour remédier à cela, un équilibrage artificiel a été effectué par duplication des classes minoritaires, ce qui a permis d'uniformiser la distribution (12 000 images pour chaque grande classe, 7830 pour AK, etc). Cette approche a amélioré la couverture des classes minoritaires lors de l'entraînement, ce qui a contribué à la hausse de l'AUC. En effet, un AUC aussi élevé traduit une capacité du modèle à séparer correctement les distributions de sortie pour chaque classe, même lorsqu'il s'agit de lésions visuellement similaires.

Analyse de la matrice de confusion : La figure 4.3a montre que les classes BCC, NV, et BKL sont particulièrement bien reconnues (fortes diagonales). En revanche, des confusions notables persistent :

- entre MEL et NV (275 cas),
- entre BKL et NV, BCC ou AK,
- entre BCC et AK.

Ces erreurs peuvent s'expliquer par des similarités visuelles importantes entre certaines lésions, mais aussi par la redondance introduite par la duplication, qui, si elle améliore la sensibilité (Recall), peut également entraîner une baisse de l'Accuracy, car le modèle devient trop confiant sur des exemples répétés, au détriment de la diversité des représentations.

Compromis AUC–Accuracy : Le fait d'obtenir un AUC très élevé (99.41%) tout en conservant une accuracy légèrement inférieure à certaines études (92.17%) illustre un compromis bien connu entre ces deux métriques. L'AUC étant insensible à la distribution des classes, il met en valeur la capacité à classer correctement indépendamment des seuils. À l'inverse, l'Accuracy est affectée par les biais de fréquence des classes. Ce compromis est particulièrement pertinent ici : la duplication a permis de renforcer la capacité du modèle à détecter les classes rares (hausse de l'AUC), mais au prix d'une légère baisse de l'Accuracy en raison de la redondance artificielle.

Modèle de détection d'images

Le modèle de détection YOLOv8 Nano a montré une très bonne performance en détectant la peau dans les images avec une précision de **99.2%** et un rappel de **99.3%**. Ces résultats confirment la capacité du modèle à distinguer efficacement les images pertinentes pour l'analyse dermatologique tout en limitant les faux positifs et les faux négatifs. Le modèle présente une très bonne capacité de généralisation, avec un taux d'erreur inférieur à 1% sur l'ensemble des classes testées.

Cependant, des erreurs de détection ont été observées dans des cas où les images étaient floues, mal éclairées, ou où la peau était partiellement masquée. De plus, des objets présentant des textures similaires à la peau ont parfois été mal détectés, ce qui peut entraîner des faux positifs. Une amélioration de la qualité des images d'entrée, ainsi qu'une meilleure gestion des variations de lumière et de contexte, pourrait améliorer les performances du modèle.

4.5.2 Forces et faiblesses du système

Forces

- **Bonnes performances globales** : Les modèles proposés, en particulier le modèle binaire et le modèle de détection, ont montré des résultats solides sur les données de test, avec des performances de haut niveau en termes de précision et d'AUC.
- **Interface utilisateur fonctionnelle** : Les interfaces pour les applications desktop et mobile sont bien conçues, permettant une utilisation facile et intuitive.
- **Traitement automatique des images** : Le système utilise un modèle pour la détection automatique des images de peau ce qui permet de traiter automatiquement les images et d'améliorer l'efficacité du processus de diagnostic.

Faiblesses

- **Confusion entre certaines classes** : Le modèle de classification multi-classes présente des difficultés à distinguer les lésions bénignes proches du mélanome, ce qui peut entraîner des erreurs de classification.
- **Sensibilité à la qualité des images** : Les résultats sont fortement influencés par la qualité des images en entrée. Des images floues, mal éclairées ou avec un fond perturbateur peuvent nuire à la précision des prédictions.
- **Erreurs de segmentation sur des cas difficiles** : Bien que le modèle de détection soit performant, des erreurs de segmentation se produisent sur des cas complexes, comme les images avec des textures ou des angles de vue inhabituels.

4.5.3 Axes d'amélioration

Pour améliorer la performance du système, plusieurs pistes peuvent être explorées :

- **Amélioration de la gestion du déséquilibre des classes** : Bien que l'augmentation de données ait permis d'atténuer certains problèmes, un meilleur équilibrage des classes et l'intégration de techniques plus avancées pourraient améliorer les résultats pour les classes moins représentées.
- **Affinement des masques de segmentation** : La précision des masques de segmentation peut être améliorée en affinant les algorithmes de segmentation ou en utilisant des modèle de segmentation comme U-Net.
- **Amélioration de la qualité des images** : L'intégration de techniques de pré-traitement d'image plus avancées, comme la réduction du bruit et l'amélioration du contraste, pourrait améliorer les performances globales du modèle.
- **Optimisation des modèles pour des environnements réels** : Les performances du modèle doivent être optimisées pour fonctionner efficacement dans des conditions réelles, avec des variations de lumière et des situations de capture d'images non idéales.

4.5.4 Synthèse de la discussion

En résumé, bien que les résultats obtenus soient globalement satisfaisants, plusieurs améliorations peuvent être apportées pour rendre le système plus robuste et performant dans des conditions réelles. Les progrès futurs se concentreront sur la gestion du déséquilibre des classes, l'amélioration de la segmentation, et l'optimisation des modèles pour des applications dans des environnements à ressources limitées.

4.6 Conclusion

Ce chapitre a permis de valider les performances des modèles proposés via des expérimentations rigoureuses. Malgré certaines limites, le système présente un bon potentiel pour assister au diagnostic précoce du cancer de la peau. Les axes d'amélioration incluent une meilleure gestion du déséquilibre des classes, le raffinement des masques de segmentation, et l'intégration de modèles plus robustes.

Conclusion Générale et Perspectives

Conclusion Générale

Ce projet s'inscrit dans le champ de l'intelligence artificielle appliquée à la médecine, et plus spécifiquement dans le cadre de la détection assistée par ordinateur du cancer de la peau à partir d'images dermatologiques. L'objectif central de ce travail était de concevoir un système complet, intelligent et autonome, capable d'analyser une image de lésion cutanée, d'identifier la région d'intérêt, et de fournir un diagnostic préliminaire fiable à l'aide de modèles d'apprentissage profond (deep learning).

Le projet a été structuré selon une méthodologie rigoureuse en plusieurs phases successives :

- **Prétraitement et préparation des données** : La base de données *ISIC 2019* a été adoptée comme corpus principal, en raison de sa richesse et de sa diversité pathologique. Un pipeline de traitement d'image a été mis en place comprenant : le redimensionnement des images à une résolution standard, la normalisation des pixels, et l'application d'une stratégie d'augmentation contrôlée (flipping, rotation, zoom, etc.) afin de traiter le déséquilibre entre classes et d'améliorer la capacité de généralisation des modèles.
- **Développement de modèles de classification** : Deux approches complémentaires ont été implémentées :
 - Un modèle de **classification binaire**, visant à distinguer les lésions *bénignes* des lésions *malignes*. Ce modèle a atteint une exactitude de **89,29%** et une surface sous la courbe ROC (AUC) de **94.91%**, démontrant une performance robuste sur le jeu de test.
 - Un modèle de **classification multiclass**, capable de différencier plusieurs types de pathologies (MEL, BKL, BCC, etc.). Celui-ci a obtenu une précision de **92.17%** et une AUC de **0.99** sur l'ensemble de validation ISIC. Toutefois, des tests sur des images externes ont révélé un léger phénomène de *surapprentissage* (overfitting), suggérant la nécessité d'un affinage ou d'un domaine d'adaptation.
- **Détection automatique des lésions avec YOLOv8** : Afin d'automatiser la

localisation des régions cutanées pertinentes, un modèle de détection **YOLOv8** (You Only Look Once) a été entraîné sur des annotations personnalisées. Ce modèle permet d'identifier automatiquement la zone contenant la lésion à partir d'une image brute (non recadrée), facilitant ainsi la **collecte, l'extraction et le traitement de données** ciblées pour les étapes ultérieures de classification.

- **Développement d'une application Desktop connectée** : Une application bureautique a été développée avec une interface graphique conviviale. Elle est interfacée avec un système embarqué basé sur un **Raspberry Pi** et une caméra, permettant l'acquisition en temps réel d'images dermatologiques. L'utilisateur peut ainsi capturer une image, détecter automatiquement la lésion, puis lancer une classification instantanée via les modèles intégrés.
- **Prototype d'application mobile** : En complément, une version mobile expérimentale a été conçue, permettant à l'utilisateur de photographier une lésion cutanée avec son smartphone. L'image est ensuite analysée localement par un modèle optimisé (TensorFlow Lite), et un résultat diagnostique est généré. Cette solution vise une accessibilité accrue pour les zones rurales ou à faible accès aux soins spécialisés.

L'ensemble de ces contributions vise à proposer une solution intelligente, portable, et facilement déployable dans des contextes médicaux contraints, notamment dans les environnements à ressources limitées. Ce projet s'inscrit ainsi dans une dynamique de médecine augmentée par l'IA, avec un fort potentiel d'impact en santé publique.

Perspectives

Plusieurs améliorations peuvent être envisagées pour renforcer la robustesse, la précision et l'utilité clinique du système :

1. **Validation clinique** : Soumettre les modèles à des tests réels en collaboration avec des dermatologues afin de valider leur efficacité en conditions réelles.
2. **Amélioration de la robustesse** : Enrichir l'entraînement avec des bases de données issues de sources diverses, et appliquer des méthodes d'apprentissage semi-supervisé ou d'adaptation de domaine pour améliorer la généralisation.
3. **Segmentation fine** : Intégrer un modèle de *segmentation* (comme U-Net ou SegFormer) pour localiser avec précision la lésion avant la classification.
4. **Suivi médical longitudinal** : Intégrer un module de suivi dans l'application mobile permettant de comparer l'évolution d'une lésion dans le temps.
5. **Déploiement sur le cloud** : Développer des versions optimisées du système pour le *cloud computing* pour le traitement centralisé

En conclusion, le système développé constitue une base solide pour une solution intelligente de dépistage précoce des cancers de la peau. Avec des validations cliniques rigoureuses et une amélioration continue des performances, il pourrait devenir un outil d'aide au diagnostic médical accessible et fiable.

Bibliographie

- [1] Lébini Chabi ADJOBO. « Amélioration du diagnostic du cancer de la peau par classification des images de dermoscopie à l'aide de techniques d'intelligence artificielle ». NNT : 2023UBFCK103. Thèse de doct. Université Bourgogne Franche-Comté ; Université d'Abomey-Calavi (Bénin), 2023. URL : <https://tel.archives-ouvertes.fr/tel-04607949>.
- [2] WORLD HEALTH ORGANIZATION. *Skin cancers*. <https://www.who.int/news-room/fact-sheets/detail/skin-cancers>. Accessed 13 June 2025. 2022.
- [3] AMERICAN ACADEMY OF DERMATOLOGY ASSOCIATION. *Largest study on racial differences in men with melanoma shows men with skin of color have lowest survival rates*. Accessed : 2025-06-16. American Academy of Dermatology. Juill. 2023. URL : <https://www.aad.org/news/melanoma-study-men-skin-of-color-lowest-survival-rates>.
- [4] Dirk SCHADENDORF et al. « Melanoma ». In : *The Lancet* 392.10151 (2018), p. 971-984. DOI : 10.1016/S0140-6736(18)31559-9.
- [5] Caroline ROBERT. « A decade of immune-checkpoint inhibitors in cancer therapy ». In : *Nature Communications* 11.1 (2020), p. 3801. DOI : 10.1038/s41467-020-17670-y.
- [6] Azam JAFARZADEH, Amin POUR MOHAMMAD, Hassan KERAMATI et al. « Regenerative medicine in the treatment of specific dermatologic disorders : a systematic review of randomized controlled clinical trials ». In : *Stem Cell Research & Therapy* 15.1 (2024), p. 176. DOI : 10.1186/s13287-024-03800-6.
- [7] Georgios NIKOLAKIS et al. « Insights, Advantages, and Barriers of Teledermatology vs. Face-to-Face Dermatology for the Diagnosis and Follow-Up of Non-Melanoma Skin Cancer : A Systematic Review ». In : *Cancers* 16.3 (2024), p. 578. DOI : 10.3390/cancers16030578.
- [8] S. MICHELINI et al. « Combining Reflectance Confocal Microscopy, Optical Coherence Tomography, and Ex-Vivo Fluorescence Confocal Microscopy for Margin Assessment in Basal Cell Carcinoma Excision ». In : *Dermatology Practical & Conceptual* 14.2 (2024), e2024090. DOI : 10.5826/dpc.1402a90.

- [9] S.S. CHAKRABORTY, A. PANJA, S. DUTTA et al. « Advancements in nanoparticles for skin care : a comprehensive review of properties, applications, and future perspectives ». In : *Discover Materials* 4.17 (2024). DOI : 10.1007/s43939-024-00088-4.
- [10] Andre ESTEVA et al. « Dermatologist-level classification of skin cancer with deep neural networks ». In : *Nature* 542.7639 (2017), p. 115-118.
- [11] Qianwei LIU, Jie ZHANG et Yanping BAI. « Mapping the landscape of artificial intelligence in skin cancer research : a bibliometric analysis ». In : *Frontiers in Oncology* 13 (2023), p. 1222426. DOI : 10.3389/fonc.2023.1222426. URL : <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10613074/>.
- [12] HAENSSLE et al. « Man against machine : diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists ». In : *Annals of Oncology* 29.8 (2018), p. 1836-1842.
- [13] TSCHANDL et al. « Comparison of the accuracy of human readers versus machine-learning algorithms for pigmented skin lesion classification : an open, web-based, international, diagnostic study ». In : *The Lancet Oncology* 20.7 (2020), p. 938-947.
- [14] Prof Scott W MENZIES et al. « Comparison of humans versus mobile phone-powered artificial intelligence for the diagnosis and management of pigmented skin cancer in secondary care : a multicentre, prospective, diagnostic, clinical trial ». In : *The Lancet Digital Health* 5.8 (2023), e679-e691.
- [15] Daneshjouand ROXANA et al. « Disparities in dermatology AI performance on a diverse , curated clinical image set ». In : *Science Advances* 8.31 (2022), eabq6147. DOI : 10.1126/sciadv.abq6147.
- [16] Jesutofunmi A. OMIYE et al. « Principles, applications, and future of artificial intelligence in dermatology ». In : *Frontiers in Medicine* 10 (2023), p. 1278232. DOI : 10.3389/fmed.2023.1278232.
- [17] Roxana R. DANESHJOU, Veronica ROTEMBERG et the INTERNATIONAL SKIN IMAGING COLLABORATION ARTIFICIAL INTELLIGENCE WORKING GROUP. « Checklist for evaluation of image-based artificial intelligence reports in dermatology : CLEAR Derm consensus guidelines from the International Skin Imaging Collaboration Artificial Intelligence Working Group ». In : *JAMA Dermatology* 158.1 (2022), p. 90-96. DOI : 10.1001/jamadermatol.2021.4915.
- [18] Idris Bibet Badaoui AYMEN. *State of the Art of Skin Anomaly Detection Using Machine Learning Techniques*. Rapp. tech. Ecole nationale superieure de technologies avancées, Département Génie Electrique et Informatique Industrielle, 2025.

- [19] N. Dalal; B. TRIGGS. « Histograms of oriented gradients for human detection ». In : *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE. 2005, p. 886-893.
- [20] M Jones P VIOLA. « Rapid object detection using a boosted cascade of simple features ». In : *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. T. 1. IEEE. 2001, p. I-I.
- [21] Pedro F. Felzenszwalb; Ross B. Girshick; David McAllester; Deva RAMANAN. « Object detection with discriminatively trained part-based models ». In : *IEEE transactions on pattern analysis and machine intelligence* 32.9 (2010), p. 1627-1645.
- [22] BRUNELLI. « Template matching techniques in computer vision : theory and practice ». In : (2009).
- [23] R. ASWIN, J. JALEEL et S. SALIM. « Artificial neural network based detection of skin cancer ». In : *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering* 1 (2012), p. 200-205.
- [24] Wei LAI et al. « Skin cancer diagnosis (SCD) using Artificial Neural Network (ANN) and Improved Gray Wolf Optimization (IGWO) ». In : *Scientific Reports* 13 (2023), p. 19377. DOI : 10.1038/s41598-023-45039-w.
- [25] akinrinade OLUSOJI et Chunglin DU. « Skin Cancer Detection Using Deep Machine Learning Techniques ». In : *Intelligence-Based Medicine* 11 (2025), p. 100191. DOI : 10.1016/j.ibmed.2024.100191.
- [26] Prasitthichai NARONGLERDRIT et Iosif MPORAS. « Evaluation of Big Data Based CNN Models in Classification of Skin Lesions with Melanoma ». In : *2020 International Conference on Artificial Intelligence and Computer Engineering (ICAICE)*. IEEE, 2020, p. 133-137. DOI : 10.1007/978-981-15-6321-8_5.
- [27] Nobuyuki OTSU. « A Threshold Selection Method from Gray-Level Histograms ». In : *IEEE Transactions on Systems, Man, and Cybernetics* 9.1 (1979), p. 62-66. DOI : 10.1109/TSMC.1979.4310076.
- [28] Hongyi ZHANG et al. « mixup : Beyond Empirical Risk Minimization ». In : *International Conference on Learning Representations (ICLR)*. 2018.
- [29] Sangdoo YUN et al. « CutMix : Regularization Strategy to Train Strong Classifiers with Localizable Features ». In : *IEEE International Conference on Computer Vision (ICCV)*. 2019, p. 6023-6032.
- [30] Erwin Setyo NUGROHO, Igi ARDIYANTO et Hanung Adi NUGROHO. « Addressing Imbalance ISIC-2019 Dataset in Dermoscopic Pigmented Skin Lesion Classification ». In : *ICIC Express Letters* 18.6 (2024), p. 563-573.

- [31] A.A. ALI et H. AL-MARZOUQI. « Melanoma Detection Using Regular Convolutional Neural Networks ». In : *2017 International Conference on Electrical and Computing Technologies and Applications (ICECTA)*. Ras Al Khaimah, United Arab Emirates : IEEE, 2017, p. 1-5.
- [32] E. NASR-ESFAHANI et al. « Melanoma Detection by Analysis of Clinical Images Using Convolutional Neural Network ». In : *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. Orlando, FL, USA : IEEE, 2016, p. 1373-1376.
- [33] Andrés Mauricio Fernández JOJOA et al. « Melanoma diagnosis using deep learning techniques on dermoscopic images ». In : *BMC Medical Imaging* 21.6 (2021).
- [34] Habeba MAHMOUD et al. « Classifying Melanoma in ISIC Dermoscopic Images Using Efficient Convolutional Neural Networks and Deep Transfer Learning ». In : *Transmission and Distributed Generation Systems* 41.2 (2024), p. 679-691. DOI : 10.18280/ts.410211.
- [35] Md Ashraful Alam MILTON. « Automated Skin Lesion Classification Using Ensemble of Deep Neural Networks in ISIC 2018 : Skin Lesion Analysis Towards Melanoma Detection Challenge ». In : *arXiv e-prints* (jan. 2019). Available at <https://arxiv.org/abs/1901.10802>. eprint : 1901.10802.
- [36] M. A. KASSEM, K. M. HOSNY et M. M. FOUAD. « Skin lesions classification into eight classes for ISIC 2019 using deep convolutional neural network and transfer learning ». In : *IEEE Access* 8 (2020), p. 114822-114832. DOI : 10.1109/ACCESS.2020.3004619.
- [37] B. OZDEMIR et I. PACAL. « A robust deep learning framework for multiclass skin cancer classification ». In : *Scientific Reports* 15.1 (2025), p. 4938. DOI : 10.1038/s41598-025-12345-6.