

République algérienne démocratique et populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'enseignement supérieur et de la recherche scientifique
جامعة عين تموشنت بلحاج بوشعيب
Université –Ain Temouchent- Belhadj Bouchaib
Faculté de Science et Technologie
Département D'électronique et des Télécommunications



Projet de Fin d'Etudes

Dans le cadre de l'arrêté ministériel 1275
« Un diplôme, une startup ou brevet d'invention »
Pour l'obtention du diplôme de Master en :
Filière : Électronique
Spécialité : Electronique Instrumentation

DERMA DOCTOR

Développement d'un système intelligent pour le diagnostic des maladies dermatiques

Présenté Par :

Damou Mohamed Oussama M2 Électronique Instrumentation
Belakdar Ismail M2 Électronique Instrumentation

Devant le jury composé de :

Dr SEKKAL Mansouria	MCA	U.Ain Témouchent	Encadrant
Dr FEROUANI Souheyla	MCA	U.Ain Témouchent	Présidente
Dr BADIR Benkrelifa Lahouaria	MCB	U.Ain Témouchent	Examineur
Dr BENOSMANE Morad	MCB	U.Ain Témouchent	Représentant de l'incubateur
Dr HADDOU	MEDCIN	Ain Témouchent	Partenaire socioéconomique

Année Universitaire: 2023/2024



REMERCIEMENTS

Nous exprimons notre profonde gratitude envers Dieu le Tout-Puissant pour nous avoir accordé la santé et la volonté nécessaires pour entreprendre et mener à bien ce projet de fin d'études.

Tout d'abord, nous tenons à remercier chaleureusement **Dr. SEKKAL Mansouria**, notre encadrant, pour sa disponibilité, ses conseils éclairés et son accompagnement tout au long de ce projet. Son expertise et ses orientations nous ont été d'une aide précieuse.

Nous souhaitons également exprimer notre gratitude envers les membres du jury qui ont accepté d'évaluer notre travail. Leur expertise et leurs commentaires constructifs ont contribué à améliorer la qualité de notre mémoire.

Nous tenons à remercier tous nos professeurs qui nous ont enseigné au cours de ces années d'études. Leurs connaissances et leur dévouement ont été essentiels pour notre formation.

Nous adressons un grand merci à nos familles et à nos amis, qui nous ont encouragés et soutenus moralement durant toutes les étapes de ce projet. Leur compréhension et leur patience ont été d'une importance capitale dans les moments d'intensité et de défi.

Enfin, nous souhaitons remercier mutuellement nos efforts et notre collaboration, qui ont permis de relever les défis de ce projet avec détermination et efficacité.

RESUME

Ce mémoire présente le développement d'un modèle intelligent pour la **détection automatique des maladies dermatologiques**, en particulier les lésions cutanées, grâce à des techniques d'**Intelligence Artificielle (IA)** et d'**Apprentissage Profond (Deep Learning)**. Face aux défis liés au diagnostic manuel, notamment sa lenteur, ses coûts élevés et ses erreurs possibles, nous avons conçu un système basé sur une architecture **MobileNetV2**, qui offre un équilibre entre précision et rapidité.

À partir de la base de données **HAM10000**, contenant des images de sept types de lésions dermatologiques, le modèle a été entraîné en deux phases : un **entraînement initial** avec des couches gelées pour extraire les caractéristiques essentielles, suivi d'un **fine-tuning** pour optimiser les performances. Ce processus a permis d'obtenir une **précision globale de 82 %**, démontrant l'efficacité du modèle proposé.

Le modèle a ensuite été intégré dans une application web interactive déployée via **TensorFlow.js**, permettant aux utilisateurs de soumettre des images de lésions directement dans un navigateur pour obtenir des prédictions instantanées. Ce travail constitue une avancée significative vers une **solution automatisée et accessible** pour la détection précoce des maladies dermatologiques, avec un potentiel d'amélioration grâce à des validations cliniques futures et à l'intégration de fonctionnalités avancées.

***Mots clés :** Maladies dermatologiques, Deep Learning, MobileNetV2, Intelligence Artificielle, Classification, TensorFlow.js, HAM10000, Diagnostic automatique.*

ABSTRACT

This thesis presents the development of an intelligent model for **automatic detection of dermatological diseases**, particularly skin lesions, using **Artificial Intelligence (AI)** and **Deep Learning** techniques. Faced with challenges related to manual diagnosis, including its slowness, high costs, and potential errors, we designed a system based on a **MobileNetV2** architecture, which provides a balance between accuracy and speed.

Using the **HAM10000** dataset, which contains images of seven types of dermatological lesions, the model was trained in two phases: an **initial training** with frozen layers to extract essential features, followed by **fine-tuning** to optimize performance. This process resulted in a **global accuracy of 82%**, demonstrating the effectiveness of the proposed model.

The model was then integrated into an interactive web application deployed via **TensorFlow.js**, allowing users to submit images of lesions directly through a browser to receive instant predictions. This work marks a significant step toward an **automated and accessible solution** for the early detection of dermatological diseases, with potential improvements through future clinical validation and the integration of advanced features.

Keywords : *Dermatological diseases, Deep Learning, MobileNetV2, Artificial Intelligence, Classification, TensorFlow.js, HAM10000, Automated diagnosis.*

ملخص

تقدم هذه الأطروحة تطوير نموذج ذكي للكشف التلقائي عن الأمراض الجلدية، وخاصة آفات الجلد، باستخدام تقنيات الذكاء الاصطناعي والتعلم العميق. في مواجهة تحديات التشخيص اليدوي، بما في ذلك بطئه وتكلفته المرتفعة والأخطاء المحتملة، قمنا بتصميم نظام يعتمد على بنية (موبيل نات) و الذي يوفر التوازن بين الدقة والسرعة

من قاعدة البيانات، التي تحتوي على صور لسبعة أنواع من الآفات الجلدية، تم تدريب النموذج على مرحلتين: تدريب أولي بالطبقات المجمدة لاستخراج الميزات الأساسية، يليه ضبط دقيق لتحسين الأداء. وقد أدت هذه العملية إلى دقة إجمالية بلغت 82%، مما يدل على فعالية النموذج المقترح.

تم بعد ذلك دمج النموذج في تطبيق ويب تفاعلي تم نشره عبر ، مما يسمح للمستخدمين بإرسال صور الآفات مباشرة إلى المتصفح للحصول على تنبؤات فورية. يمثل هذا العمل خطوة مهمة إلى الأمام نحو حل آلي وسهل الوصول إليه للكشف المبكر عن الأمراض الجلدية، مع إمكانية التحسين من خلال التحقق السريع المستقبلية ودمج الوظائف المتقدمة

الكلمات المفتاحية: الأمراض الجلدية، التعلم العميق، الذكاء الاصطناعي، التصنيف، التشخيص التلقائي

Table Des Matières

1	Chapitre 1 : Les Maladies Dermatologiques et le Cancer de la Peau.....	16
1.1	Introduction.....	16
1.2	Définition des maladies dermatologique :	16
1.3	Classification des maladies dermatologiques :	16
	Maladies Dermatologiques Inflammatoires :.....	16
	Maladies Dermatologiques Infectieuses	17
	-Lupus érythémateux : Une maladie auto-immune qui peut affecter la peau, provoquant des éruptions cutanées, notamment sur le visage.....	17
1.4	Importance du Diagnostic Précoce des Maladies de la Peau :.....	17
1.4.1	Prévention des Cancers de la Peau :	18
1.4.2	Réduction des Complications :	18
1.4.3	Amélioration de la Qualité de Vie :	18
1.4.4	Éviter les Traitements Inutiles :.....	18
1.4.5	Suivi Médical et Surveillance :.....	18
1.5	Le cancer de la peau :.....	18
1.5.1	Définition :.....	18
1.5.2	Les différents types de cancer de la peau :	19
1.5.2.1	Carcinome basocellulaire (CBC) :.....	19
1.5.2.2	Carcinome spinocellulaire (CSC) :.....	19
1.5.2.3	Mélanome :.....	19
1.6	Les facteurs de risques du cancer de la peau :.....	20
1.7	Les méthodes traditionnelles de diagnostic dermatologiques :	21
1.7.1	Examen clinique et biopsie :.....	21
1.7.1.1	Examen clinique :.....	21
1.7.1.2	Biopsie :	21
1.7.2	Limites des méthodes conventionnelles :	22
1.8	L'importance de la détection assistée par ordinateur (DAO) :.....	22
1.8.1	-Avantage de la DAO :.....	22
	Précision accrue.....	22
1.9	Conclusion :	23
2	Chapitre 2 :Intelligence Artificielle et Deep Learning.....	24
2.1	Introduction à l'Intelligence Artificielle et Apprentissage Automatique.....	24
2.2	Définition et historique de l'intelligence artificielle (IA) :	24

2.3	Apprentissage automatique (ML) :.....	24
2.3.1	Applications de l'apprentissage automatique :.....	24
2.3.2	Apprentissage supervisé, non supervisé et par renforcement :	26
	Apprentissage supervisé :.....	26
	Entraînement :.....	26
2.4	L'Apprentissage Profond (Deep Learning) :.....	30
2.4.1	L'importance de l'apprentissage profond :	31
	1. Révolution dans le traitement des données complexes :	31
2.4.2	Applications pratiques et impact dans divers secteurs :.....	31
	-Finance :.....	32
	Dans le secteur financier, l'apprentissage profond est utilisé pour :.....	32
2.5	Les réseaux de neurones profonds (DNN) :.....	32
2.5.1	Architecture d'un DNN :	33
2.5.2	Types d'architectures de DNN :.....	35
2.6	Différences entre l'apprentissage profond et l'apprentissage automatique traditionnel :..	36
	1. Extraction des caractéristiques :	36
	2. Volume de données :.....	36
	3. Puissance de calcul :	37
	4. Applications :	37
2.7	Introduction aux réseaux de neurones convolutifs (CNN) :	37
2.7.1	Processus d'apprentissage d'un CNN :	37
2.7.2	Architecture des Réseaux de Neurones Convolutifs (CNN) :.....	38
2.7.3	Application des CNN en Analyse d'Images Médicales :.....	39
2.7.4	Avantages des CNN pour le traitement d'images :	40
2.8	Transfert de connaissances (transfer learning) :.....	40
2.8.1	Principe du Transfert de Connaissances :.....	40
2.8.2	Importance du Transfert de Connaissances :.....	41
2.8.3	Applications en Analyse d'Images Médicales :.....	41
2.9	Architectures de CNN populaire (ResNet, MobileNet, EfficientNet) :	42
2.9.1	ResNet (Residual Network) :	42
	Description :	42
	Caractéristiques principales :.....	42
	Applications :	42
2.9.2	MobileNet :.....	42

-Description :	42
-Caractéristiques principales :	42
-Applications :	43
2.9.3 EfficientNet :	43
Description :	43
Caractéristiques principales :	43
Applications :	43
2.10 Deep learning dans la détection du cancer de la peau :	44
2.10.1 Approche et Technologies Utilisées :	44
2.10.2 Étapes du Processus :	44
2.10.3 Exemples de Modèles Utilisés dans la Détection du Cancer de la Peau :	45
2.10.4 Utilisation de l'apprentissage profond pour la classification des lésions cutanées :....	45
2.10.5 Principes de l'Apprentissage Profond pour la Classification des Lésions Cutanées :....	45
2.10.6 Avantages et Limites de l'Apprentissage Profond dans la Dermatologie :	46
2.10.6.1 Avantages de l'Apprentissage Profond dans la Dermatologie :	47
2.10.6.2 Limites de l'Apprentissage Profond dans la Dermatologie :	47
2.10.7 Défis et Perspectives de l'IA en Médecine Dermatologique :	49
2.10.7.1 Défis :	49
2.10.7.2 Perspectives :	49
2.10.8 Enjeux éthique et considération réglementaire :	50
2.10.8.1 Enjeux Éthiques :	50
2.10.8.2 Considérations Réglementaires :	51
2.10.8.3 Solutions et Initiatives :	51
2.10.9 Les défis liés aux biais de données et aux interprétations des modèles IA :	51
2.10.9.1 Biais de Données :	52
Pour les biais de données :	53
Pour l'interprétabilité :	53
2.10.10 Le future de l'IA dans le diagnostic dermatologique et le suivi des patients :	53
2.11 Conclusion :	54
3 Chapitre 3 :Le développement du model intelligent	55
3.1 Introduction.....	55
3.2 Travail Réalisé :	56
3.2.1 La base de donnes :	56
3.2.2 Répartition des données :	56

3.2.3	Architecture du Modèle, Processus d'Entraînement et Environnement de Travail :....	57
	Configuration utilisée dans Google Colab :	57
3.2.4	Architecture du Modèle :	58
3.2.5	Personnalisation pour HAM10000 :	58
3.2.6	Processus d'Entraînement :	59
3.3	Résultats et Discussion :	61
3.3.1	Matrice de Confusion :	61
3.3.2	Interprétation de la matrice :	62
3.3.3	Rapport de Classification :	62
	Métriques globales :	63
3.3.4	Discussion des Résultats :	64
3.4	Conclusion :	64
4	Chapitre 4 : Présentation de L'application	66
4.1	Création de l'application Dermadoctor :	66
4.1.1	Objectifs de l'application :	66
4.1.2	Technologies utilisées :	66
4.1.3	Fonctionnalités principales :	67
4.1.4	Étapes de développement :	68
4.1.5	Organisation des fichiers :	70
	L'application est structurée comme suit :	70
4.2	Résultats attendus :	70
4.3	Conclusion :	70

Liste Des Figures

Figure4.1 Les différents types de cancer de la peau.....	20
figure5.1 Les étapes de l'apprentissage supervisé	26
figure 5.2 Les différents cas d'utilisation de l'apprentissage supervisé.....	27
figure 5.3 Les différents cas d'utilisation de l'apprentissage non-supervisé.....	28
figure 5.4 Structure d'un DNN	33
figure 5.5 Courbe de la fonction sigmoïde et ReLU	34
figure 5.6 Architecture des réseaux de Neurons Convolutifs(CNN)	39
figure 6.1 Exemple de DTTA Augmentation.....	59
figure 6.2 L'évolution de la précision du modèle	60
figure 6.3 Perte du modèle	61
figure 6.4 Le rapport de classification.....	62
figure 7.1 Loge de L'application.....	66
figure 7.2 Chargement de l'image et l'affichage de résultat	68
figure 7.3 Un graphique à barres montre le résultat.....	68
figure 7.4 Implémentation de l'application.....	69

Liste Des Tableau

2.1 Les avantages et les limites de l'apprentissage profond dans la dermatologie.....	49
3.1 Ham 10000	58

DEDICACE

Belakhdar Ismail

À mes parents, (**Mohamed et Hayat**), pour leur amour inconditionnel, leur soutien sans faille et leurs sacrifices.

À ma sœur (**Soumia**), pour ta bienveillance, ta force et ton inspiration.

À mon frère (**Imad**) et son épouse, (**Docteur Takwa**), pour leur encouragement et leur présence précieuse.

À mes deux chères nièces, (**Malek et Farah**) véritables princesses de mon cœur, pour leur joie de vivre et leurs sourires radieux.

Et enfin, à mon binôme (**Oussama**), pour ta loyauté, ton amitié et ta précieuse complicité.

Cette réussite vous est dédiée, car sans vous, rien de tout cela n'aurait été possible

DEDICACE

Damou Mohamed Oussama

En témoignage d'amour et d'affection, je suis très fière de dédicacer cet ouvrage simple à tous mes proches :

Ma chère maman qui a contribué à ma réussite par son amour, son soutien inconditionnel, ses sacrifices et ses précieux conseils. Je suis reconnaissant pour toute son aide et sa présence continue dans ma vie.

Mon cher père, qui peut retrouver ici avec fierté le résultat des sacrifices et des privations qu'il a consentis au fil des années pour m'aider à avancer dans la vie. Que Dieu le bénisse et que je continue à réussir et lui apporte bonheur et satisfaction.

Mes SIX sœurs et mon frère que Dieu vous accorde la santé, le bonheur et la réussite dans tous vos efforts.

En fin mon meilleur amie ISMAIL.

- Introduction générale

Les maladies dermatologiques, en particulier le **cancer de la peau**, constituent un enjeu majeur de santé publique à l'échelle mondiale. Leur **prévalence croissante** et les complications associées à un diagnostic tardif mettent en évidence la nécessité d'une détection rapide et précise. Parmi ces pathologies, le **mélanome** et les autres lésions cutanées malignes figurent parmi les principales causes de mortalité liées aux cancers, surtout lorsqu'ils ne sont pas diagnostiqués et traités à temps.

- Contexte et Problématique

Le **diagnostic manuel** repose essentiellement sur l'expertise des dermatologues à partir d'examen cliniques et d'images médicales. Toutefois, cette méthode présente des **limites importantes** :

- Elle est **coûteuse** en temps et en ressources, particulièrement dans les régions où l'accès à des spécialistes qualifiés est restreint.
- Le processus peut être **subjectif** et parfois imprécis, en raison de la complexité des lésions et de leur ressemblance visuelle avec d'autres affections bénignes.
- La **charge de travail élevée** pour les professionnels de santé peut entraîner des erreurs ou des délais dans la prise en charge des patients

Dans ce contexte, les technologies innovantes telles que l'**Intelligence Artificielle (IA)** et l'**Apprentissage Profond (Deep Learning)** apparaissent comme des solutions prometteuses. Les **réseaux de neurones convolutifs (CNN)**, largement utilisés pour l'analyse d'images, ont démontré leur capacité à rivaliser, voire surpasser, les experts humains dans la détection et la classification de maladies dermatologiques à partir d'images médicales.

- Objectifs

La disponibilité de grandes bases de données médicales telles que **HAM10000** a permis aux chercheurs de développer et d'entraîner des modèles intelligents capables de distinguer les types de lésions cutanées

L'objectif est donc de développer un modèle performant, capable d'identifier automatiquement différentes lésions cutanées, puis de le déployer dans une application web pour une utilisation **simple, rapide et accessible**.

Les principaux objectifs de ce travail sont les suivants :

1. **Analyser et prétraiter des données médicales** : Utilisation de la base **HAM10000** contenant des images de lésions cutanées pour entraîner un modèle d'apprentissage automatique.

2. **Développer un modèle de classification basé sur le Deep Learning** : Entraîner un réseau de neurones convolutifs, en utilisant une architecture performante comme **MobileNetV2** et des techniques d'optimisation telles que le **fine-tuning** et la **Data Augmentation**.
3. **Évaluer les performances du modèle** : Analyser les résultats obtenus en termes de précision, rappel et F1-score, ainsi que les métriques comme la matrice de confusion.
4. **Déployer le modèle dans une application web** : Intégrer le modèle avec **TensorFlow.js** pour permettre un diagnostic rapide et interactif dans un navigateur, accessible aux utilisateurs finaux (professionnels ou patients).
5. **Élaborer un Business Model Canvas** : Proposer une structure économique pour le déploiement de l'application et analyser sa viabilité.

- [Structure du Mémoire](#)

Le présent mémoire est structuré en **quatre chapitres** comme suit :

- **Chapitre 1 : Les maladies dermatologiques et le cancer de la peau**
Ce chapitre présente une revue des principales maladies dermatologiques, avec un accent particulier sur les cancers de la peau. Nous y détaillerons les causes, les symptômes et les méthodes traditionnelles de diagnostic.
- **Chapitre 2 : Intelligence Artificielle et Deep Learning**
Ce chapitre introduit les concepts théoriques liés à l'IA et au Deep Learning, avec un focus sur les réseaux de neurones convolutifs (CNN) utilisés pour l'analyse d'images médicales.
- **Chapitre 3 : Développement du modèle intelligent**
Ce chapitre détaille l'ensemble des étapes techniques pour développer notre modèle :
 - Description de la base de données HAM10000.
 - Prétraitement des images et augmentation des données.
 - Architecture du modèle MobileNetV2 et processus d'entraînement.
 - Évaluation des performances obtenues (précision, rappel, matrice de confusion).
- **Chapitre 4 : Présentation de l'application**
Ce chapitre présente le déploiement pratique de notre modèle dans une application web interactive à l'aide de TensorFlow.js. Nous y expliquons l'interface utilisateur et les tests réalisés.
- **Conclusion et perspectives**
Une synthèse des résultats obtenus, ainsi que les perspectives d'amélioration et d'extension de l'application dans un contexte réel.
- **Business Model Canvas (BMC)**
Une analyse des aspects économiques et stratégiques pour assurer la mise en œuvre et la pérennité de notre projet.

1 Chapitre 1 : Les Maladies Dermatologiques et le Cancer de la Peau

1.1 Introduction

Les maladies dermatologiques désignent un ensemble de pathologies affectant la peau, qui est l'organe le plus vaste du corps humain. La peau joue un rôle crucial en protégeant l'organisme contre les agressions extérieures, tout en régulant diverses fonctions vitales, comme la thermorégulation et la perception sensorielle. Cependant, elle est également susceptible de développer de nombreuses affections, certaines bénignes et d'autres plus graves, comme le cancer de la peau. Ce chapitre présente les bases des maladies dermatologiques, leur classification, ainsi que l'importance d'un diagnostic précoce pour un traitement efficace.

Dans ce chapitre on va parler sur les maladies dermatologiques en général et notamment sur le cancer de la peau et ces différents types et L'importance de la détection assistée par ordinateur (DAO).

1.2 Définition des maladies dermatologique :

Les maladies dermatologiques sont des affections de la peau qui peuvent résulter de divers facteurs, tels que des infections, des troubles hormonaux, des maladies auto-immunes, des réactions allergiques ou des facteurs environnementaux. Elles comprennent aussi bien des affections courantes et bénignes, comme l'acné ou l'eczéma, que des pathologies graves, telles que les cancers cutanés (mélanome, carcinome basocellulaire, etc.).

Ces maladies peuvent affecter non seulement l'apparence de la peau, mais aussi ses fonctions, provoquant des douleurs, des démangeaisons, des infections et, dans certains cas, des complications graves si elles ne sont pas traitées à temps. Il existe de nombreuses formes de maladies dermatologiques qui nécessitent une prise en charge appropriée.

1.3 Classification des maladies dermatologiques :

Les maladies dermatologiques peuvent être classées de plusieurs manières, mais une classification commune se base sur la nature des affections et leur étiologie (origine). Voici les principales catégories :

Maladies Dermatologiques Inflammatoires :

-Dermatite atopique (eczéma) : Affection inflammatoire de la peau, souvent d'origine génétique, qui provoque des démangeaisons, des rougeurs et une peau sèche.

-Psoriasis : Maladie auto-immune qui accélère le renouvellement cellulaire de la peau, provoquant des plaques rouges et squameuses.

-Acné : Affection cutanée fréquente chez les adolescents, caractérisée par l'apparition de boutons, points noirs et kystes, souvent en raison d'un excès de sébum.

Maladies Dermatologiques Infectieuses :

-Infections fongiques : Comme la teigne, la candidose ou les mycoses, qui affectent la peau, les cheveux et les ongles.

-Infections virales : Comme l'herpès, la varicelle, ou les verrues, souvent causées par des virus spécifiques.

-Infections bactériennes : Par exemple, l'impétigo, une infection bactérienne qui provoque des lésions cutanées purulentes.

Maladies Dermatologiques Auto-immunes :

-Lupus érythémateux : Une maladie auto-immune qui peut affecter la peau, provoquant des éruptions cutanées, notamment sur le visage.

-Pemphigus : Une affection rare qui provoque la formation de cloques et d'ulcères sur la peau, causée par des anticorps attaquant les cellules de la peau.

Maladies Dermatologiques Dérivées de Facteurs Environnementaux :

-Cancers de la peau : Les cancers cutanés, tels que le mélanome et le carcinome basocellulaire, sont largement associés à l'exposition excessive au soleil ou aux rayons UV.

-Vieillesse cutané : Les rides, les taches brunes et l'élasticité réduite de la peau peuvent être causées par le vieillissement naturel de la peau ou par une exposition excessive au soleil.

Maladies Dermatologiques Générales :

-Allergies cutanées : Certaines affections de la peau résultent d'une réaction allergique, comme l'urticaire ou les réactions à des produits cosmétiques.

-Acrodermatite : Une affection cutanée rare mais grave qui survient souvent après des infections virales.

1.4 Importance du Diagnostic Précoce des Maladies de la Peau :

Le diagnostic précoce des maladies dermatologiques revêt une importance capitale, car il permet de prévenir les complications graves, d'éviter des traitements inutiles et de réduire les risques à long terme. Voici quelques raisons pour lesquelles il est essentiel de diagnostiquer rapidement une maladie dermatologique :

1.4.1 Prévention des Cancers de la Peau :

Le cancer de la peau, et notamment le mélanome, est l'un des types de cancers les plus fréquents et les plus graves. Le diagnostic précoce permet de traiter ces cancers avant qu'ils ne se propagent à d'autres parties du corps. Si détecté tôt, le mélanome peut être guéri dans la majorité des cas par une simple intervention chirurgicale pour retirer la lésion cancéreuse.

1.4.2 Réduction des Complications :

Certaines maladies dermatologiques, comme les infections bactériennes ou fongiques, peuvent s'aggraver rapidement et provoquer des complications. Un diagnostic précoce permet d'appliquer un traitement rapide, limitant ainsi les risques de propagation de l'infection et de complications sévères, comme des cicatrices permanentes ou des infections systémiques.

1.4.3 Amélioration de la Qualité de Vie :

Les maladies dermatologiques, même bénignes, peuvent affecter la qualité de vie des individus, en particulier lorsqu'elles provoquent des symptômes comme des douleurs, des démangeaisons ou des désagréments esthétiques. Un traitement précoce permet de soulager rapidement les symptômes et d'améliorer le bien-être général des patients.

1.4.4 Éviter les Traitements Inutiles :

Un diagnostic rapide et précis permet d'éviter des traitements inappropriés ou inutiles. Par exemple, certains traitements pour des affections bénignes peuvent être lourds et coûteux. La prise en charge d'une maladie dès ses premiers signes permet de prescrire des traitements plus efficaces et moins invasifs.

1.4.5 Suivi Médical et Surveillance :

Dans le cas des maladies chroniques comme le psoriasis ou l'eczéma, un diagnostic précoce permet de mettre en place un suivi médical adapté, avec des traitements pour gérer la maladie au fil du temps et minimiser ses impacts.

1.5 Le cancer de la peau :

1.5.1 Définition :

Le cancer de la peau est l'un des cancers les plus courants dans le monde, mais également l'un des plus évitables grâce à des mesures de prévention simples et efficaces. Cette maladie survient lorsque des cellules de la peau commencent à se développer de manière incontrôlée,

formant des tumeurs. L'exposition excessive aux rayons ultraviolets (UV) du soleil ou des sources artificielles comme les cabines de bronzage est le principal facteur de risque. Le cancer de la peau se manifeste sous différentes formes, dont le carcinome basocellulaire, le carcinome spinocellulaire et le mélanome, ce dernier étant le plus dangereux. Une détection précoce et un traitement approprié peuvent garantir un pronostic favorable, d'où l'importance de la surveillance régulière de la peau et de la sensibilisation aux comportements de protection solaire.

1.5.2 Les différents types de cancer de la peau :

Il existe plusieurs types de cancer de la peau, qui se distinguent par leur origine cellulaire et leur comportement. Les principaux types de cancer cutané sont :

1.5.2.1 Carcinome basocellulaire (CBC) :

Le carcinome basocellulaire est le type de cancer de la peau le plus courant. Il se développe à partir des cellules basales de l'épiderme, qui sont situées dans la couche la plus profonde de la peau. Ce type de cancer est généralement localisé et se propage rarement à d'autres parties du corps.

Caractéristiques :

- Apparition de nodules ou de petites lésions brillantes, parfois translucides, souvent avec des vaisseaux sanguins visibles.
- Les zones fréquemment touchées sont le visage, le cou et les oreilles.
- Croissance lente et peu agressive.

1.5.2.2 Carcinome spinocellulaire (CSC) :

Le carcinome spinocellulaire se développe à partir des cellules squameuses (cellules de la couche externe de l'épiderme). Il est plus agressif que le carcinome basocellulaire et peut se propager à d'autres parties du corps, bien que cela soit rare.

Caractéristiques :

- Lésions rouges, épaisses et squameuses, parfois ulcérées.
- Peut saigner ou croître rapidement.
- Il est souvent associé à des zones de peau endommagées par le soleil, comme les lèvres, les oreilles ou le cuir chevelu.

1.5.2.3 Mélanome :

Le mélanome est un cancer de la peau plus rare, mais également le plus dangereux. Il se développe à partir des mélanocytes, les cellules responsables de la production de pigment

(mélanine). Le mélanome peut se propager rapidement aux autres organes si non détecté à temps.

Caractéristiques :

- Apparition de taches de couleur irrégulière (noir, brun, rouge, bleu) ou d'une nouvelle tache qui change de forme, de taille et de couleur.
- Bordures irrégulières, parfois avec des saignements ou des démangeaisons.
- Il peut apparaître n'importe où sur le corps, mais il est plus fréquent sur le dos chez les hommes et sur les jambes chez les femmes.



Figure1.1 Les différents types de cancer de la peau.

1.6 Les facteurs de risques du cancer de la peau :

Différents facteurs peuvent accroître les risques de cancer de la peau. Parmi eux, l'exposition aux rayons du soleil est particulièrement significative. On estime, en effet, qu'environ deux tiers des cancers de la peau sont imputables aux UV, qu'ils soient naturels (soleil) ou artificiels (cabine de bronzage). Des coups de soleil intenses pendant l'enfance, même sporadiques, sont considérés comme d'importants facteurs favorisants. De même, une exposition régulière et prolongée au soleil (sans qu'il y ait forcément de coups de soleil) est également un facteur de risque.

D'autres facteurs individuels sont également à prendre en considération. Le type de peau et de cheveux entre en ligne de compte, les personnes aux cheveux sombres et à la peau claire étant considérées comme plus à risque. La présence de nombreux grains de beauté ou d'affections cutanées chroniques est aussi un facteur de risque. Enfin, les antécédents familiaux et médicaux de chaque personne peuvent impacter ses risques de développer un jour un cancer de la peau.

Le cancer de la peau fait partie des quelques pathologies cancéreuses dites « à bon pronostic », c'est-à-dire qui offrent de bonnes chances de guérison à long terme lorsqu'elles sont correctement prises en charge. Pour bénéficier d'une prise en charge efficace, il demeure essentiel de diagnostiquer au plus tôt la maladie, lorsqu'elle ne se trouve pas encore à un stade avancé. L'auto dépistage, qui consiste à inspecter régulièrement sa peau à la recherche d'anomalies, devrait donc faire partie de la routine santé de chacun, surtout passé l'âge de 50 ans, alors que les risques de cancer de la peau sont accrus.

1.7 Les méthodes traditionnelles de diagnostic dermatologiques :

Le diagnostic dermatologique repose historiquement sur des méthodes classiques qui se sont avérées essentielles pour identifier, classifier et traiter une variété d'affections cutanées. Ces méthodes incluent principalement l'examen clinique et la biopsie cutanée.

1.7.1 Examen clinique et biopsie :

1.7.1.1 Examen clinique :

L'examen clinique est souvent la première étape dans le diagnostic dermatologique du cancer de la peau. Il consiste en une évaluation visuelle détaillée des lésions cutanées, à la recherche de signes caractéristiques de cancer, tels que des changements dans la taille, la forme, la couleur, ou l'apparence d'un grain de beauté ou d'une autre lésion. Lors de cet examen, le dermatologue prend en compte plusieurs critères :

- **Asymétrie** : Une lésion dont la forme est irrégulière peut être suspecte.
- **Bords irréguliers** : Les taches avec des bords mal définis sont plus souvent associées au cancer de la peau.
- **Couleur variable** : La présence de plusieurs couleurs dans une lésion est un signe d'alerte.
- **Diamètre** : Les lésions de grande taille (supérieures à 6 mm) peuvent indiquer un risque accru de cancer.
- **Évolution** : Les changements dans une lésion, tels que sa croissance rapide, des saignements ou des démangeaisons, nécessitent une investigation approfondie.

L'examen clinique reste un outil précieux, mais il est souvent subjectif et peut ne pas détecter de manière fiable les cancers cutanés, notamment dans les stades précoces.

1.7.1.2 Biopsie :

La biopsie cutanée est la méthode diagnostique la plus fiable pour confirmer un cancer de la peau. Elle consiste à prélever un échantillon de tissu de la lésion suspecte pour l'analyser au microscope. Il existe plusieurs types de biopsies :

- **Biopsie par excision** : Elle consiste à retirer complètement la lésion, offrant un diagnostic et un traitement en une seule procédure.
- **Biopsie par incisions** : Une petite portion de la lésion est retirée pour analyse.

- **Biopsie par ponction** : Une aiguille est utilisée pour prélever un échantillon de tissu de la lésion.

La biopsie permet de différencier les différents types de cancers cutanés, notamment le carcinome basocellulaire, le carcinome spinocellulaire, et le mélanome, chacun nécessitant un traitement spécifique.

1.7.2 Limites des méthodes conventionnelles :

Bien que l'examen clinique et la biopsie soient des méthodes fondamentales, elles présentent plusieurs limites :

- **Subjectivité de l'examen clinique** : L'interprétation des signes cliniques peut varier d'un professionnel à l'autre. Par exemple, des lésions bénignes peuvent être confondues avec des lésions cancéreuses, et vice versa.
- **Difficulté de détection des lésions précoces** : Les cancers de la peau, notamment les mélanomes, peuvent commencer par des lésions très petites et difficiles à distinguer des taches bénignes. Cela rend leur détection précoce plus complexe.
- **Biopsie invasive** : Bien que la biopsie soit fiable, elle est invasive et comporte des risques de complications, telles que des infections ou des cicatrices. De plus, elle ne permet pas de visualiser la lésion dans son ensemble, ce qui peut entraîner un diagnostic erroné si la biopsie n'est pas réalisée sur la partie la plus suspecte de la lésion.
- **Limites des biopsies multiples** : Dans certains cas, la biopsie peut ne pas être suffisante pour déterminer avec précision la profondeur d'invasion du cancer, ce qui est crucial pour le pronostic, notamment dans le cas des mélanomes.

1.8 L'importance de la détection assistée par ordinateur (DAO) :

L'importance croissante de la détection assistée par ordinateur (DAO) dans le diagnostic du cancer de la peau est devenue évidente avec les progrès technologiques dans le domaine de l'imagerie médicale et de l'intelligence artificielle (IA). La DAO permet d'améliorer la précision et la rapidité du diagnostic dermatologique en automatisant une partie du processus d'analyse des lésions cutanées. Cette approche repose sur des algorithmes d'IA et des techniques d'apprentissage automatique pour analyser les images des lésions cutanées et détecter les signes de malignité.

1.8.1 -Avantage de la DAO :

Précision accrue : Les systèmes de DAO peuvent identifier des caractéristiques subtiles que l'œil humain pourrait manquer, comme de petites variations de couleur ou de texture, augmentant ainsi la précision du diagnostic.

Détection précoce : La DAO permet de repérer des cancers de la peau à un stade précoce, lorsqu'ils sont encore de petite taille et plus faciles à traiter.

Réduction de la subjectivité : L'IA élimine la variabilité humaine dans l'interprétation des images, ce qui garantit une évaluation plus cohérente et objective des lésions.

Accessibilité accrue : L'utilisation de DAO dans les zones géographiques manquant de spécialistes dermatologiques permet de faciliter l'accès au diagnostic, notamment en milieu rural ou dans les pays à ressources limitées.

-Application de la DAO :

- **Analyse des images cliniques** : Des logiciels comme DermExpert et MelaFind analysent les images des lésions cutanées prises par un dermatologue ou un professionnel de santé pour détecter les signes de cancer de la peau, en particulier le mélanome.
- **Systèmes de télémedecine** : L'utilisation d'algorithmes d'IA permet à des spécialistes de poser un diagnostic à distance en analysant des images envoyées par des médecins locaux ou des patients eux-mêmes.

La DAO ne remplace pas l'examen clinique ni la biopsie, mais elle constitue un complément précieux, permettant un diagnostic plus rapide et plus précis, et réduisant le risque d'erreurs humaines.

1.9 Conclusion :

Dans ce chapitre on a parlé tout d'abord des maladies dermatologiques et en suite sur le cancer de la peau : sa définition et ces différents types ainsi que les méthodes traditionnelles de diagnostic et a la fin l'importance de la détection assistée par ordinateur (DAO) .

2 Chapitre 2 : Intelligence Artificielle et Deep Learning

2.1 Introduction à l'Intelligence Artificielle et Apprentissage Automatique

L'Intelligence Artificielle (IA) et l'Apprentissage Automatique (Machine Learning, ML) sont des domaines en pleine expansion qui transforment de nombreux secteurs, y compris la santé, l'automobile, la finance et bien d'autres. Ces technologies ont été largement adoptées pour leur capacité à résoudre des problèmes complexes en traitant d'énormes quantités de données et en faisant des prédictions ou des classifications à partir de celles-ci.

Dans ce chapitre on va parler sur Intelligence Artificielle et Deep Learning et leur application et son importance et en particulier l'utilisation de deep learning pour la prédiction du cancer de la peau.

2.2 Définition et historique de l'intelligence artificielle (IA) :

L'Intelligence Artificielle (IA) est un sous-ensemble de l'informatique qui s'intéresse à la création de machines ou de logiciels capables d'exécuter des tâches qui, normalement, nécessitent une intelligence humaine. Ces tâches incluent des processus comme la reconnaissance vocale, la prise de décision, le raisonnement logique, la traduction automatique et la reconnaissance d'images.

Le concept d'IA remonte aux années 1950, avec des pionniers comme Alan Turing, qui a formulé le célèbre test de Turing en 1950 pour évaluer si une machine peut imiter l'intelligence humaine. Cependant, l'IA n'a pris son essor que dans les années 2000 grâce aux avancées en puissance de calcul et à l'explosion des données numériques. Les premières approches de l'IA reposaient sur des systèmes experts et des règles programmées manuellement, mais les progrès récents se sont orientés vers des méthodes d'apprentissage automatique et d'apprentissage profond.

2.3 Apprentissage automatique (ML) :

Est un champ d'étude de l'intelligence artificielle qui vise à donner aux machines la capacité d'« apprendre » à partir de données, via des modèles mathématiques.

2.3.1 Applications de l'apprentissage automatique :

L'apprentissage automatique est utilisé dans de nombreux domaines, en voici quelques exemples :

1. Reconnaissance d'images et de vision par ordinateur :

- **Exemple :** Classification d'images (reconnaissance faciale), détection d'objets (véhicules autonomes), diagnostic médical (analyse d'images médicales).

2. Traitement du langage naturel (NLP) :

- **Exemple :** Traduction automatique (Google Translate), chat bots, analyse de sentiments (réseaux sociaux, service client), génération de texte (Chat GPT).

3. Recommandation de produits et services :

- **Exemple :** Systèmes de recommandation utilisés par des plateformes comme Netflix, Amazon, et Spotify pour suggérer des films, des articles ou des chansons en fonction des préférences de l'utilisateur.

4. Prédiction et analyse des données :

- **Exemple :** Prédiction des tendances boursières, détection des fraudes bancaires, analyse des risques d'assurance, maintenance prédictive (prévoir les pannes de machines avant qu'elles ne surviennent).

5. Conduite autonome :

- **Exemple :** Voitures autonomes comme celles développées par Tesla ou Waymo, où des algorithmes d'apprentissage automatique ont été utilisés pour analyser l'environnement, prendre des décisions en temps réel et conduire en toute sécurité.

6. Santé et biotechnologie :

- **Exemple :** Diagnostic médical automatisé, prédiction de maladies (comme le cancer), recherche de médicaments, personnalisation des traitements en fonction des données génétiques.

7. Automatisation industrielle et robotique :

- **Exemple :** Robots industriels qui utilisent l'apprentissage pour améliorer leur efficacité et s'adapter aux changements dans le processus de production.

8. Sécurité informatique :

- **Exemple :** Détection d'attaques informatiques, identification de logiciels malveillants, surveillance des réseaux pour détecter des anomalies et des intrusions.


2.3.2 Apprentissage supervisé, non supervisé et par renforcement :

Apprentissage supervisé :

L'apprentissage supervisé en machine learning consiste à enseigner à un ordinateur à reconnaître des schémas dans les données en lui fournissant des exemples étiquetés. Ces exemples sont des paires de données, où chaque entrée est associée à une sortie attendue. L'ordinateur utilise ces exemples pour apprendre à faire des prédictions précises sur de nouvelles données. En d'autres termes, il apprend à partir de "bons exemples" où la bonne réponse est déjà connue, afin de pouvoir généraliser et faire des prédictions sur des données non vues auparavant.

L'apprentissage supervisé est largement utilisé dans de nombreux domaines, notamment la reconnaissance d'images, la détection de spam, la prédiction de prix, la recommandation de produits, entre autres.

Le processus d'apprentissage supervisé se déroule généralement en plusieurs étapes :



Les étapes de l'apprentissage supervisé en Machine Learning

2.1 Les étapes de l'apprentissage supervise

Entraînement :

Pendant cette phase, l'algorithme est exposé à un ensemble de données d'entraînement qui contient des exemples étiquetés. L'algorithme ajuste ses paramètres internes en analysant ces données pour apprendre à faire des prédictions précises.

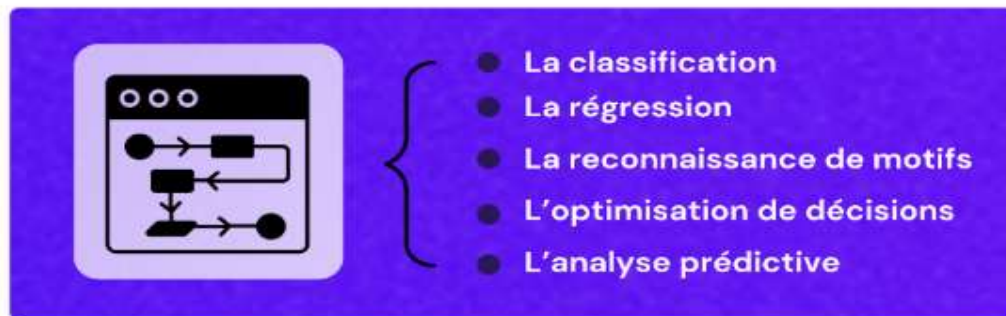
Validation :

Après l'entraînement, l'algorithme est évalué sur un ensemble de données de validation distinct pour estimer ses performances et ajuster ses hyper paramètres (paramètres qui contrôlent le processus d'apprentissage).

Test :

Enfin, une fois que l'algorithme a été entraîné et validé, il est testé sur un ensemble de données de test distinct pour évaluer ses performances réelles sur des données qu'il n'a jamais vues auparavant. Cela permet d'estimer à quel point l'algorithme est précis par rapport aux données non vues.

Les différents cas d'utilisation de l'apprentissage supervisé



2.2 Les différents cas d'utilisation de l'apprentissage supervisé

-La classification :

Utile lorsque vous avez des données avec des étiquettes ou des catégories prédéfinies et que vous souhaitez prédire à quelle catégorie une nouvelle observation appartient. Par exemple, la détection de spam dans les e-mails, la classification de documents, la reconnaissance faciale, etc.

-La régression :

Quand vous avez des données numériques et que vous souhaitez prédire une valeur continue. Par exemple, la prédiction des prix des maisons en fonction de leurs caractéristiques, la prévision des ventes en fonction de divers facteurs, etc.

-Reconnaissance de motifs :

Si vous avez des données avec des schémas ou des tendances sous-jacentes et que vous souhaitez les extraire. Par exemple, dans l'analyse de séries temporelles pour identifier des tendances ou des saisons, dans la détection de fraudes pour repérer des schémas inhabituels dans les transactions, etc. Cela peut vous aider, en tant que Data Scientist à construire des modèles prédictifs, en utilisant le modèle ARIMA ou SARIMAX.

-Optimisation de décisions :

Utile lorsque vous souhaitez automatiser des décisions basées sur des critères préétablis. Par exemple, dans les systèmes de recommandation pour recommander des produits ou des

contenus à des utilisateurs en fonction de leurs préférences passées, dans la personnalisation du contenu sur les plateformes en ligne, etc.

-Analyse prédictive :

Incontournable si vous souhaitez utiliser des données historiques pour prédire des événements futurs. Par exemple, dans la prévision de la demande pour ajuster les niveaux de stocks, dans la prédiction des performances d'un étudiant en fonction de ses caractéristiques démographiques et académiques, etc.

Apprentissage non supervisé :

L'apprentissage non-supervisé en machine learning consiste à analyser des données sans étiquettes ni réponses préétablies. Contrairement à l'apprentissage supervisé, où le modèle est entraîné sur des exemples étiquetés pour prédire des résultats, l'apprentissage non-supervisé cherche à découvrir des structures ou des modèles intrinsèques dans les données elles-mêmes. Cela peut inclure des tâches telles que :

- le regroupement de données similaires en clusters,
- la réduction de la dimensionnalité pour simplifier la représentation des données
- la détection d'anomalies pour identifier des comportements inhabituels,
- la découverte de motifs fréquents ou d'associations entre les variables

L'apprentissage non-supervisé est utilisé pour explorer et découvrir des informations cachées dans les données non étiquetées.

Les différents cas d'utilisation de l'apprentissage non-supervisé



2.3 Les différents cas d'utilisation de l'apprentissage non-supervisé

-Le clustering de données :

Lorsque vous avez un ensemble de données non étiquetées et que vous souhaitez découvrir des structures intrinsèques ou des groupes naturels au sein de ces données. Par

exemple, regrouper les clients en segments de marché basés sur leurs comportements d'achat, regrouper les articles de presse en clusters thématiques, etc.

-La détection d'anomalies :

Vous souhaitez identifier des exemples ou des observations qui se comportent de manière significativement différente du reste des données. Cela peut être utile pour détecter la fraude dans les transactions financières, les pannes dans les systèmes industriels, les comportements suspects dans les réseaux informatiques, etc.

-La réduction de dimensionnalité :

Si vous avez un grand nombre de variables ou de dimensions dans vos données et que vous souhaitez réduire leur complexité en conservant les informations importantes. Cela peut être utile pour la visualisation des données, l'accélération des algorithmes d'apprentissage supervisé.

-La détection d'associations :

Indispensable lorsque vous souhaitez découvrir des motifs fréquents, des règles d'association ou des tendances cachées dans vos données. Par exemple, identifier les achats fréquents de produits dans un supermarché, découvrir des motifs saisonniers dans les données météorologiques, etc.

-La segmentation de marché :

Incontournable pour diviser un marché en segments homogènes en fonction des caractéristiques des clients, des produits ou des comportements. Cela peut être utile pour personnaliser les offres marketing, cibler des groupes spécifiques de clients, etc.

-Le traitement de données non structurées :

Lorsque vous avez des données non structurées, ce sont des images, du texte, de l'audio, etc., et que vous souhaitez extraire des informations utiles ou découvrir des structures sous-jacentes. Par exemple, la segmentation automatique d'images médicales, la classification automatique de documents textuels, la recommandation de musique basée sur les préférences auditives, etc.

Apprentissage par renforcement :

L'apprentissage par renforcement (RL) est une technique de machine learning (ML) qui entraîne les logiciels à prendre des décisions en vue d'obtenir les meilleurs résultats. Elle imite le processus d'apprentissage par tâtonnements employé par les êtres humains pour atteindre leurs objectifs. Les actions logicielles qui contribuent à la réalisation de votre objectif sont renforcées, tandis que les actions qui nuisent à celle-ci sont ignorées.

Les algorithmes de RL utilisent un paradigme de récompense et de punition lorsqu'ils traitent les données. Ils apprennent du retour d'information de chaque action et découvrent par eux-mêmes les chemins de traitement optimaux pour atteindre les résultats finaux. Les

algorithmes sont également capables de différer la gratification. La meilleure stratégie globale peut exiger des sacrifices à court terme. Ainsi, l'approche la plus efficace qu'ils découvrent peut inclure des punitions ou des retours en arrière. Le RL est une méthode puissante qui aide les systèmes d'intelligence artificielle (IA) à obtenir des résultats optimaux dans des environnements invisibles.

-Les avantages de l'apprentissage par renforcement

L'apprentissage par renforcement (RL) présente de nombreux avantages. En voici les trois principaux.

1. Excelle dans les environnements complexes

Les algorithmes de RL peuvent être utilisés dans des environnements complexes comportant de nombreuses règles et dépendances. Dans un même environnement, un être humain n'est pas toujours capable de déterminer le meilleur chemin à suivre, même s'il possède une connaissance supérieure de cet environnement. En revanche, les algorithmes de RL sans modèles adaptent rapidement aux environnements en constante évolution et trouvent de nouvelles stratégies pour optimiser les résultats.

2. Nécessite moins d'interactions humaines

Dans les algorithmes de ML classiques, un être humain doit étiqueter les paires de données pour guider l'algorithme ; ce processus n'est pas nécessaire avec un algorithme de RL, car il apprend seul. Dans le même temps, il propose des mécanismes permettant d'intégrer des commentaires humains qui aident à créer des systèmes s'adaptant aux préférences, à l'expertise et aux corrections humaines.

3. Optimiser les actions pour atteindre des objectifs à long terme

Le RL se concentre intrinsèquement sur la maximisation des récompenses à long terme, ce qui le rend idéal dans les scénarios où les actions ont des conséquences prolongées. Il est adapté aux situations réelles où chaque étape n'est pas immédiatement commentée, car l'algorithme peut apprendre des récompenses différées.

Par exemple, les décisions relatives à la consommation ou au stockage d'énergie peuvent avoir des conséquences à long terme : il est possible d'utiliser le RL pour optimiser l'efficacité énergétique et les coûts à long terme. Avec des architectures adéquates, les agents de RL peuvent aussi généraliser leurs stratégies apprises sur des tâches similaires mais non identiques.

2.4 L'Apprentissage Profond (Deep Learning) :

L'apprentissage profond (ou Deep Learning) est une sous-catégorie de l'apprentissage automatique (Machine Learning) qui repose sur des réseaux de neurones artificiels ayant de nombreuses couches. Ces réseaux, appelés réseaux neuronaux profonds, sont capables de modéliser des représentations hiérarchiques complexes des données. Le terme "profond" fait référence à l'usage de plusieurs couches d'unités (ou neurones) pour apprendre des

caractéristiques de plus en plus abstraites à mesure que l'information passe à travers les couches successives.

2.4.1 L'importance de l'apprentissage profond :

L'importance de l'apprentissage profond (deep learning) dans le monde moderne est considérable, car cette technologie a profondément transformé des secteurs clés et a permis de réaliser des avancées spectaculaires dans plusieurs domaines. Voici les principaux aspects de son importance :

1. Révolution dans le traitement des données complexes :

L'un des grands avantages de l'apprentissage profond est sa capacité à traiter des données non structurées comme les images, les vidéos, les textes et les sons. Avant son développement, l'analyse de ces données nécessitait des méthodes manuelles ou des modèles moins performants. Grâce à l'apprentissage profond, les systèmes sont désormais capables d'extraire des caractéristiques pertinentes directement à partir des données brutes, sans nécessiter une intervention humaine pour extraire les règles.

- **Images et vidéos :** Les réseaux neuronaux convolutifs (CNN) ont permis des progrès majeurs en vision par ordinateur, comme la reconnaissance d'images, la détection d'objets, la segmentation d'images, et même la reconnaissance faciale.
- **Langage naturel :** Les modèles comme GPT ou BERT ont révolutionné le traitement automatique du langage, permettant des tâches comme la traduction automatique, la génération de texte, l'analyse de sentiments, et la reconnaissance vocale.
- **Audio :** L'apprentissage profond a également permis des avancées majeures dans la reconnaissance vocale, la synthèse vocale, et la transcription automatique.

2.4.2 Applications pratiques et impact dans divers secteurs :

L'apprentissage profond a des applications concrètes et transforme de nombreux domaines, avec des bénéfices à la clé pour les entreprises, les gouvernements, et la société dans son ensemble.

-Santé :

L'une des applications les plus prometteuses de l'apprentissage profond réside dans le domaine médical :

- **Diagnostic précoce :** Les réseaux neuronaux sont utilisés pour analyser des images médicales (radiographies, IRM, scanners) et détecter des maladies comme le cancer, les tumeurs, ou les maladies cardiaques.
- **Médecine personnalisée :** L'IA peut analyser les dossiers médicaux et les données génétiques pour aider à personnaliser les traitements pour chaque patient.

- **Systèmes d'aide à la décision :** L'IA assiste les médecins dans la prise de décisions en fournissant des recommandations basées sur une analyse de données massives.

-Transport et véhicules autonomes :

L'apprentissage profond joue un rôle central dans le développement des véhicules autonomes (voitures, drones, robots), permettant à ces systèmes de :

- **Reconnaître l'environnement :** À l'aide de capteurs et de caméras, les véhicules autonomes utilisent des réseaux neuronaux pour détecter et comprendre leur environnement (voitures, piétons, panneaux de signalisation, etc.).
- **Prendre des décisions en temps réel :** Les véhicules peuvent analyser des données en temps réel pour naviguer, éviter des obstacles et interagir avec leur environnement de manière autonome.

-Finance :

Dans le secteur financier, l'apprentissage profond est utilisé pour :

- **Prédire les tendances des marchés financiers :** Les modèles peuvent analyser d'énormes quantités de données pour identifier des modèles et prédire les évolutions boursières.
- **Détection des fraudes :** Les systèmes d'IA peuvent détecter des comportements inhabituels dans les transactions bancaires ou les cartes de crédit, permettant ainsi de prévenir les fraudes.
- **Trading algorithmique :** Les modèles d'apprentissage profond sont utilisés pour automatiser le trading, en analysant les données du marché à grande échelle et en réagissant en temps réel.


2.5 Les réseaux de neurones profonds (DNN) :

Un réseau de neurones profond est constitué de plusieurs couches de neurones, avec des connexions entre elles sous forme de poids. Les réseaux DNN sont dits "profonds" parce qu'ils possèdent plusieurs couches cachées, par opposition aux réseaux neuronaux traditionnels qui n'en possèdent généralement qu'une ou deux. Chaque couche d'un DNN applique une transformation non linéaire sur les données d'entrée, ce qui permet au réseau d'apprendre des représentations de plus en plus abstraites à chaque couche.

-Structure de base d'un DNN :

- **Entrée (Input Layer) :** Cette couche prend les données brutes (comme une image, un texte ou des caractéristiques de données structurées).
- **Couches cachées (Hidden Layers) :** Ce sont des couches intermédiaires qui effectuent des transformations sur les données d'entrée. Chaque neurone de la couche effectue une somme pondérée des entrées et applique une fonction d'activation.

- **Sortie (Output Layer) :** Cette couche produit la sortie finale du réseau, par exemple, une classe dans une tâche de classification.



2.4 Structure d'un DNN

2.5.1 Architecture d'un DNN :

L'architecture des réseaux neuronaux profonds varie en fonction des tâches et des types de données, mais en général, elle comprend plusieurs éléments clés :

a) Neurones :

Les neurones dans un DNN sont des unités de calcul simples, qui effectuent généralement les opérations suivantes :

1. **Calcul de la somme pondérée des entrées :** Chaque neurone reçoit des signaux d'entrée, qui sont multipliés par des poids.
2. **Ajout d'un biais :** Un biais est ajouté à cette somme pour permettre une meilleure flexibilité du modèle.
3. **Fonction d'activation :** Une fonction non linéaire est appliquée au résultat de la somme pondérée pour déterminer la sortie du neurone.

Les fonctions d'activation les plus courantes sont :

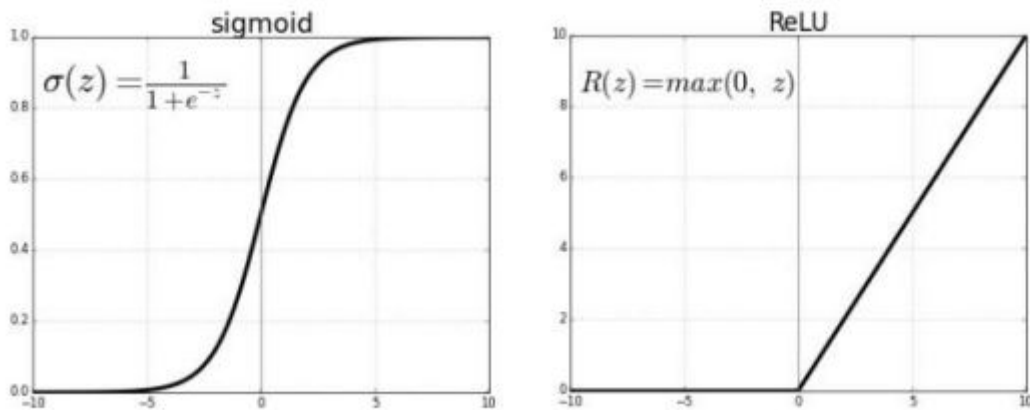
- **ReLU (Rectified Linear Unit) :** La fonction ReLU est la fonction d'activation la plus utilisée dans le monde à l'heure actuelle, puisqu'elle est utilisée dans presque tous les réseaux neuronaux convolutifs ou l'apprentissage profond.(figure2.5)

$$f(x) = \max(0, x)$$

- **Sigmoïde :** La principale raison pour laquelle nous utilisons la fonction sigmoïde est qu'elle existe entre 0 et 1. Par conséquent, elle est particulièrement utilisée pour les

modèles où nous devons prédire la probabilité en tant que sortie. Comme la probabilité de quoi que ce soit n'existe que dans la plage de 0 à 1.(figure2.5)

$$f(x) = \frac{1}{1 + e^{-x}}$$



2.5 Courbe de la fonction sigmoid et ReLU

- **Tanh (Hyperbolic Tangent)** : Plage de sortie : $[-1,1]$, Utilisée lorsque des valeurs centrées sur zéro sont souhaitées.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

b) Couches :

- **Couche d'entrée** : Contient les neurones correspondant aux caractéristiques de l'entrée du réseau.
- **Couches cachées** : Plusieurs couches de neurones où les représentations des données sont progressivement raffinées. Plus un réseau est profond, plus ces couches peuvent capturer des abstractions complexes.
- **Couche de sortie** : Produit la prédiction du réseau, qui pourrait être une classification, une régression, etc.

c) Poids et biais :

Chaque connexion entre neurones a un poids associé, et chaque neurone a un biais. Ces paramètres sont ajustés au cours de l'entraînement du réseau afin de minimiser l'erreur entre la sortie prédite et la sortie réelle.

d) Fonction de coût (Loss Function) :

La fonction de coût mesure l'erreur entre la prédiction du modèle et la vérité terrain.

e) Propagation avant et rétropropagation :

- **Propagation avant (Forward Propagation) :** Les données passent à travers les couches du réseau pour générer une prédiction.
- **Rétropropagation (Backpropagation) :** Après avoir calculé l'erreur, l'algorithme ajuste les poids et biais du réseau pour réduire cette erreur, en utilisant des méthodes d'optimisation comme la descente de gradient.

2.5.2 Types d'architectures de DNN :

Il existe plusieurs types d'architectures pour les réseaux de neurones profonds, chacune adaptée à des tâches spécifiques :

a) Perceptron multicouche (MLP - Multi-Layer Perceptron) :

C'est le type le plus simple de DNN. Il est constitué de plusieurs couches entièrement connectées, où chaque neurone est connecté à chaque neurone de la couche suivante.

- **Avantages :** Simplicité, efficace pour les problèmes où les données peuvent être représentées sous forme de vecteurs (par exemple, pour des données structurées).
- **Limites :** Moins efficace pour traiter des données non structurées comme les images ou les séquences temporelles.

b) Réseaux Convolutifs (CNN - Convolutional Neural Networks) :

Les CNN sont particulièrement efficaces pour le traitement d'images et de vidéos. Ils utilisent des filtres (ou noyaux) pour effectuer des convolutions, permettant de capturer des motifs locaux (comme les bords, les textures, etc.).

- **Avantages :** Capacité à extraire des caractéristiques locales et à réduire la dimensionnalité grâce à sous-échantillonnage (pooling).
- **Exemples d'applications :** Reconnaissance d'images, détection d'objets.

c) Réseaux Récurrents (RNN - Recurrent Neural Networks) :

Les RNN sont adaptés aux séquences de données, comme les séries temporelles, le texte ou la parole. Ils possèdent des connexions récurrentes permettant de mémoriser l'information dans le temps.

- **Avantages :** Modélisation des dépendances temporelles dans les séquences.
- **Limites :** Difficulté à capturer de longues dépendances (problème du gradient vanishing/explosion).

d) Réseaux Transformer :

Les transformer est remplacé les RNN dans de nombreuses applications modernes de traitement du langage naturel (NLP). Ils utilisent des mécanismes d'attention pour modéliser les relations entre les éléments d'une séquence, sans avoir besoin de recourir à des boucles récurrentes.

- **Avantages** : Très efficaces pour les tâches de NLP, permettant un apprentissage parallèle et la capture de relations longues-portées.
- **Exemples d'applications** : Traduction automatique, génération de texte, modèle comme GPT ou BERT.

2.6 Différences entre l'apprentissage profond et l'apprentissage automatique traditionnel :

La principale différence entre l'apprentissage profond (deep learning) et l'apprentissage automatique traditionnel (machine learning) réside dans la manière dont les caractéristiques des données sont traitées et utilisées pour effectuer des prédictions. Voici un résumé :

1. Extraction des caractéristiques :

- **Apprentissage automatique traditionnel** :
 - Nécessite une **extraction manuelle des caractéristiques** (feature engineering) par des experts.
 - L'algorithme (comme les SVM, arbres de décision, etc.) utilise ces caractéristiques pour effectuer des prédictions.
 - Exemple : Pour détecter un visage, il faut définir explicitement des caractéristiques comme les contours ou les distances entre les yeux.
- **Apprentissage profond** :
 - Apprend automatiquement les **caractéristiques pertinentes** directement à partir des données brutes grâce à des réseaux de neurones profonds.
 - Exemple : Un réseau convolutionnel (CNN) apprend les caractéristiques visuelles comme les textures ou les formes sans intervention humaine.

2. Volume de données :

- **Apprentissage automatique traditionnel** :
 - Fonctionne bien avec des ensembles de données de taille **modérée**.
 - Peut rencontrer des difficultés à gérer de grandes quantités de données complexes.
- **Apprentissage profond** :
 - Nécessite de grandes quantités de données pour former des modèles efficaces.
 - Excelle dans le traitement de **données complexes** comme les images, vidéos, ou le langage naturel.

3. Puissance de calcul :

- **Apprentissage automatique traditionnel :**
 - Peut fonctionner sur des machines avec une **puissance de calcul limitée**.
 - Les algorithmes sont souvent plus simples et rapides à entraîner.
- **Apprentissage profond :**
 - Nécessite des ressources matérielles importantes (comme des GPU) en raison de la complexité des réseaux de neurones et des calculs nécessaires.

4. Applications :

- **Apprentissage automatique traditionnel :**
 - Approprié pour des problèmes bien définis et structurés, comme la régression, la classification tabulaire ou les modèles linéaires.
- **Apprentissage profond :**
 - Idéal pour des problèmes nécessitant l'analyse de données non structurées, comme :
 - Reconnaissance d'images (vision par ordinateur).
 - Traitement automatique du langage (chatbots, traduction).
 - Jeux et prises de décision complexes.

2.7 Introduction aux réseaux de neurones convolutifs (CNN) :

Les CNN sont un type spécifique de réseau de neurones profonds qui utilisent une architecture particulière, axée sur l'exploitation de la structure spatiale des images. Ils sont très efficaces pour extraire des caractéristiques locales de l'image tout en réduisant la complexité computationnelle.

Dans un réseau CNN, l'idée principale est d'appliquer des opérations de convolution pour extraire des motifs et des caractéristiques (comme les bords, les textures, les formes, etc.) de l'image. Ces caractéristiques sont ensuite combinées pour effectuer des tâches plus complexes, comme la classification d'images ou la détection d'objets.

2.7.1 Processus d'apprentissage d'un CNN :

L'apprentissage d'un CNN se fait de manière supervisée à l'aide d'un ensemble de données étiquetées (par exemple, des images annotées avec des classes). Le processus d'entraînement implique les étapes suivantes :

1. **Initialisation des poids :** Les filtres de convolution et les poids des couches entièrement connectées sont initialisés aléatoirement.
2. **Propagation avant (Forward Propagation) :** L'image d'entrée passe à travers les couches de convolution, de pooling et les couches entièrement connectées pour produire une sortie.

3. **Calcul de l'erreur (Loss Function) :** La différence entre la sortie prédite et la vérité terrain est mesurée par une fonction de coût (par exemple, l'entropie croisée pour la classification).
4. **Rétropropagation (Backpropagation) :** L'erreur est propagée en arrière à travers le réseau, et les poids sont ajustés à l'aide d'un algorithme d'optimisation (souvent la descente de gradient).
5. **Mise à jour des poids :** Les poids des filtres et des neurones sont ajustés pour minimiser l'erreur.

Ce processus est répété sur de nombreuses itérations jusqu'à ce que le modèle converge vers un ensemble optimal de poids.

2.7.2 Architecture des Réseaux de Neurones Convolutifs (CNN) :

Les CNN sont généralement composés de plusieurs types de couches qui permettent d'extraire et d'apprendre des caractéristiques à différents niveaux d'abstraction.(figure2.6)
Voici les composants clés :

1. Couches de Convolution :

La couche de convolution est le cœur du CNN. Elle applique un ensemble de filtres (ou noyaux) sur l'image d'entrée. Chaque filtre effectue une opération de convolution qui consiste à balayer l'image avec un noyau (petite matrice de poids) et à calculer une somme pondérée des pixels voisins.

- **But :** Cette opération permet d'extraire des caractéristiques locales comme des bords, des textures, ou des motifs simples à partir de l'image.
- **Exemple :** Un filtre peut détecter des bords horizontaux, verticaux ou des motifs plus complexes en combinant plusieurs couches de convolution.

2. Couches de Pooling :

Les couches de pooling (ou sous-échantillonnage) sont utilisées après chaque couche de convolution pour réduire la taille de la représentation spatiale des images tout en conservant les informations importantes. Le pooling est souvent réalisé par une opération appelée max pooling, qui sélectionne la valeur maximale d'une sous-région de l'image (généralement une fenêtre de 2x2 ou 3x3).

- **But :** Le pooling permet de réduire la dimensionnalité, d'éviter le sur apprentissage et d'extraire des caractéristiques invariantes à de petites transformations comme la translation ou la rotation.
- **Exemple :** Si un filtre de max pooling 2x2 est appliqué, il sélectionne le pixel avec la valeur maximale dans une fenêtre de 2x2 pixels et le conserve.

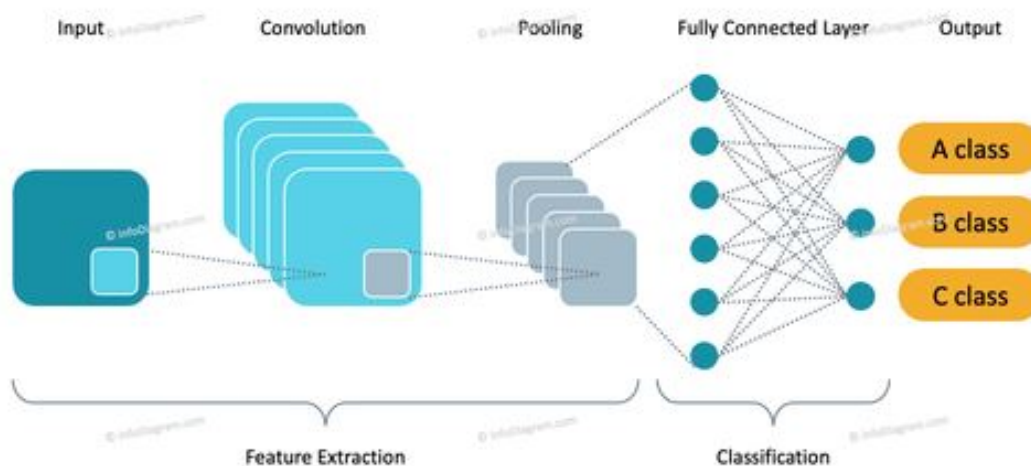
3. Couches entièrement connectées (Fully Connected Layer) :

Après avoir extrait des caractéristiques à travers plusieurs couches de convolution et de pooling, les CNN possèdent souvent des couches entièrement connectées (ou dense layers), qui sont des couches où chaque neurone est connecté à tous les neurones de la couche précédente. Ces couches sont responsables de la prise de décision finale, par exemple la classification de l'image en différentes catégories.

- **But :** Ces couches permettent de combiner les caractéristiques extraites à des niveaux plus élevés d'abstraction pour effectuer des tâches de classification ou de régression.

4. Couches d'Activation :

Introduisent des non-linéarités à l'aide de fonctions comme ReLU, sigmoid, ou softmax.



2.6 Architecture des reseaux de Neurons Convolutifs(CNN)

2.7.3 Application des CNN en Analyse d'Images Médicales :

Les CNN ont transformé l'analyse des images médicales en permettant l'automatisation et l'amélioration des diagnostics. Voici quelques exemples :

1. Détection des maladies :

- **Radiologie :** Identification des tumeurs dans les radiographies, IRM. Exemple : Détection du cancer du sein sur des mammographies.
- **Ophtalmologie :** Diagnostic de la rétinopathie diabétique à partir d'images du fond de l'œil.

2. Segmentation d'images médicales :

- Identifier les régions spécifiques dans une image (par exemple, segmenter une tumeur dans une IRM).

- Algorithmes populaires : U-Net, V-Net.
- 3. Classification des maladies :**
 - Prédiction de la présence ou de l'absence d'une pathologie en fonction des images fournies.
 - Exemple : Classification des types de pneumonie dans des radiographies thoraciques.
- 4. Analyse des histopathologies :**
 - Analyse de tissus au microscope pour détecter les cellules cancéreuses.
- 5. Suivi et évolution des pathologies :**
 - Comparaison d'images médicales sur une période pour évaluer la progression de maladies comme la sclérose en plaques.
- 6. Chirurgie assistée par l'IA :**
 - Utilisation de CNN pour fournir des visualisations en temps réel lors d'interventions chirurgicales guidées par imagerie.

2.7.4 Avantages des CNN pour le traitement d'images :

Les CNN offrent plusieurs avantages qui les rendent particulièrement adaptés au traitement d'images :

- **Extraction automatique des caractéristiques :** Contrairement à d'autres approches d'apprentissage automatique, les CNN apprennent automatiquement à extraire les caractéristiques pertinentes des images, sans nécessiter de prétraitement manuel.
- **Invariance à la translation :** Grâce aux opérations de convolution et de pooling, les CNN peuvent reconnaître des objets dans des images même s'ils sont déplacés (traduit).
- **Réduction de la complexité :** L'utilisation de convolutions permet de réduire considérablement la dimensionnalité des données d'entrée, ce qui rend l'entraînement plus rapide et moins coûteux en termes de mémoire.
- **Adaptation à différentes résolutions :** Les CNN peuvent être entraînés sur des images de résolutions variables et capturer des détails à différentes échelles.

2.8 Transfert de connaissances (transfer learning) :

Le transfert de connaissances est une technique de l'apprentissage profond où un modèle pré-entraîné sur un grand ensemble de données est réutilisé ou ajusté pour résoudre un nouveau problème avec moins de données. C'est une stratégie particulièrement utile dans des contextes où les données annotées sont limitées, comme en analyse d'images médicales.

2.8.1 Principe du Transfert de Connaissances :

- 1. Pré-entraînement sur un large dataset générique :**
 - Par exemple, ImageNet, un ensemble de données contenant des millions d'images d'objets divers.

- Le modèle apprend des caractéristiques générales (bords, textures, formes).
- 2. Fine-tuning (ajustement fin) sur un dataset spécifique :**
 - Les couches profondes du modèle sont ajustées pour le domaine cible, comme les images médicales.
 - Cette étape nécessite un ensemble de données spécifique mais plus petit que celui du pré-entraînement.

2.8.2 Importance du Transfert de Connaissances :

- 1. Réduction des besoins en données :**
 - Les données annotées dans des domaines spécialisés, comme les images médicales, sont coûteuses et rares.
 - Le transfert de connaissances permet de démarrer avec un modèle performant sans nécessiter de grandes quantités de données.
- 2. Accélération de l'entraînement :**
 - Un modèle pré-entraîné converge plus rapidement car il a déjà appris des caractéristiques générales.
- 3. Amélioration des performances :**
 - En exploitant les connaissances acquises lors du pré-entraînement, les modèles atteignent souvent une meilleure précision.
- 4. Utilisation efficace des ressources :**
 - Moins de puissance de calcul est nécessaire comparé à l'entraînement d'un modèle à partir de zéro.
- 5. Adaptabilité :**
 - Les modèles pré-entraînés sont polyvalents et peuvent être adaptés à divers domaines (radiologie, ophtalmologie, histopathologie).

2.8.3 Applications en Analyse d'Images Médicales :

- 1. Classification :**
 - Identifier des maladies spécifiques à partir de rayons X, IRM, ou tomodensitogrammes.
 - Exemple : Réutilisation de ResNet pour classifier des anomalies pulmonaires.
- 2. Segmentation :**
 - Délimiter des régions d'intérêt, comme les tumeurs ou lésions.
- 3. Détection d'anomalies :**
 - Utilisation de modèles comme Faster R-CNN pour localiser des anomalies dans des images complexes.

2.9 Architectures de CNN populaire (ResNet, MobileNet, EfficientNet) :

Ces trois architectures sont des réseaux de neurones convolutifs (CNN) populaires, chacun conçu avec des objectifs spécifiques en termes de performances, de légèreté et d'efficacité. Voici une explication claire de chacun :

2.9.1 ResNet (Residual Network) :

Description :

- Proposé par Kaiming He et al. en 2015, ResNet résout le problème de la dégradation des performances avec l'augmentation de la profondeur des réseaux.
- Il introduit les blocs résiduels, où une connexion de saut (skip connection) ajoute directement l'entrée à la sortie d'une couche intermédiaire.

Caractéristiques principales :

- **Profondeur accrue** : Permet de construire des réseaux très profonds (ResNet-50, ResNet-101) sans perte de performance.
- **Connexions résiduelles** : Facilitent l'entraînement en évitant l'atténuation des gradients.

Applications :

- Vision par ordinateur (classification d'images, détection d'objets).
- Analyse d'images médicales, comme la détection de tumeurs.

2.9.2 MobileNet :

-Description :

- Développé par Google en 2017, MobileNet est conçu pour les appareils mobiles et les environnements contraints en termes de calcul.
- Il repose sur les convolutions séparables en profondeur (depthwise separable convolutions), réduisant significativement les paramètres et les calculs.

-Caractéristiques principales :

- **Efficacité** : Réduction des coûts computationnels.
- **Personnalisabilité** : Hyperparamètres (largeur, résolution) ajustables selon les ressources disponibles.

-Applications :

- Applications embarquées, IoT, reconnaissance faciale.
- Analyse en temps réel sur des appareils mobiles.

2.9.3 EfficientNet :

Description :

- Développé par Mingxing Tan et Quoc Le en 2019, EfficientNet introduit une approche systématique pour mettre à l'échelle les réseaux neuronaux (compound scaling).
- Il ajuste simultanément la profondeur, la largeur et la résolution pour améliorer l'efficacité.

Caractéristiques principales :

- **Efficience** : Atteint des performances élevées avec un nombre réduit de paramètres.
- **Évolutivité** : Gamme de modèles (EfficientNet-B0 à B7) adaptée à différentes ressources.

Applications :

- Projets nécessitant un compromis entre précision et efficacité (classification, analyse d'images médicales).
- Réseaux pré-entraînés pour l'apprentissage par transfert.

-Comparaison :

Caractéristique	ResNet	MobileNet	EfficientNet
Profondeur	Très profond	Peu profond	Profondeur ajustable
Complexité	Moyenne	Faible	Moyenne à faible
Efficacité	Bonne	Très élevée	Optimale
Applications	Vision générale	Appareils mobiles	Domaines variés

Tableau 2 .1 Comparaison de CNN populaire (Resnet ,MobileNet,EfficientNet)

2.10 Deep learning dans la détection du cancer de la peau :

Le deep learning a transformé le domaine de la médecine, et en particulier la détection du cancer de la peau, grâce à l'usage des réseaux de neurones convolutifs (CNN) qui permettent de classifier et d'analyser les images cutanées pour identifier des signes de cancers cutanés tels que le mélanome et les carcinomes basocellulaires.

2.10.1 Approche et Technologies Utilisées :

1. Réseaux de Neurones Convolutifs (CNN) :

- Les CNN sont utilisés pour analyser les images de la peau (comme les photographies de lésions cutanées) et les classifier en fonction de leur type (bénin ou malin).
- Ils peuvent extraire automatiquement des caractéristiques pertinentes, comme les bords, les textures et les formes, ce qui permet de détecter des anomalies.
- Exemple d'architecture utilisée : **ResNet**, **Inception**, **EfficientNet**, et d'autres réseaux spécialement conçus pour la vision par ordinateur.

2. Apprentissage Supervisé et Apprentissage Transfert :

- L'apprentissage supervisé est souvent appliqué avec des ensembles de données annotées de lésions cutanées (par des dermatologues experts).
- L'apprentissage par transfert (comme l'utilisation de modèles pré-entraînés sur des ensembles d'images génériques) est couramment utilisé pour affiner les modèles et les adapter à des jeux de données spécifiques, réduisant ainsi les besoins en grandes quantités d'annotations.

2.10.2 Étapes du Processus :

1. Collecte et Préparation des Données :

- Des bases de données comme **ISIC (International Skin Imaging Collaboration)** et **HAM10000** contiennent des milliers d'images de lésions cutanées étiquetées, utilisées pour entraîner et tester les modèles de deep learning.

2. Prétraitement des Images :

- Les images sont souvent normalisées et ajustées en termes de taille et de résolution pour s'assurer que le réseau peut les analyser de manière optimale.

3. Entraînement du Modèle :

- Des CNN sont formés pour reconnaître des caractéristiques spécifiques des lésions cutanées, comme les bords irréguliers, la couleur, et la taille des taches. Ces caractéristiques aident à distinguer les lésions bénignes des malignes.

4. Évaluation et Validation :

- Les modèles sont évalués à l'aide de métriques telles que la **précision**, le **rappel**, et la **courbe ROC** pour déterminer leur efficacité dans la détection du cancer de la peau.

2.10.3 Exemples de Modèles Utilisés dans la Détection du Cancer de la Peau :

1. EfficientNet :

- Utilisé pour la classification des lésions cutanées, grâce à sa capacité à gérer des jeux de données de grande taille avec des ressources limitées.

2. ResNet et Inception :

- Ces architectures sont couramment utilisées dans la classification d'images médicales en raison de leur efficacité pour capturer des détails complexes tout en restant efficaces.

2.10.4 Utilisation de l'apprentissage profond pour la classification des lésions cutanées :

L'apprentissage profond (deep learning) a démontré une grande efficacité dans la classification des lésions cutanées, particulièrement dans le diagnostic précoce du cancer de la peau, comme le mélanome et d'autres types de carcinomes. L'approche la plus courante dans ce domaine repose sur les réseaux de neurones convolutifs (CNN), qui sont capables d'analyser les images de lésions cutanées pour identifier des caractéristiques visuelles spécifiques qui peuvent indiquer la présence de cancer.

2.10.5 Principes de l'Apprentissage Profond pour la Classification des Lésions Cutanées :

1. Réseaux de Neurones Convolutifs (CNN) :

Les CNN sont au cœur de la plupart des modèles d'apprentissage profond utilisés pour la classification des lésions cutanées. Voici pourquoi :

- **Extraction automatique des caractéristiques :** Contrairement aux méthodes traditionnelles de classification d'images qui nécessitent une extraction manuelle des caractéristiques, les CNN peuvent apprendre et extraire automatiquement les caractéristiques les plus pertinentes pour la classification des lésions cutanées (par exemple, les bords, la texture, les couleurs).
- **Supervision par des bases de données médicales :** Des bases de données contenant des milliers d'images étiquetées de lésions cutanées (telles que **ISIC**, **HAM10000**, etc.) permettent de former ces modèles à reconnaître les différences subtiles entre les lésions bénignes et malignes.

2. Étapes du Processus de Classification :

La classification des lésions cutanées via l'apprentissage profond suit un processus en plusieurs étapes :

1. **Collecte des données** : Les images de lésions cutanées sont collectées à partir de sources telles que des hôpitaux, des bases de données publiques, ou des applications mobiles. Ces images sont souvent étiquetées par des dermatologues, ce qui permet d'entraîner les modèles de manière supervisée.
2. **Prétraitement des données** : Les images sont normalisées et ajustées à une taille uniforme afin d'être compatibles avec l'architecture du réseau. Certaines techniques de data augmentation (ex. rotations, changements de luminosité) sont souvent utilisées pour améliorer la robustesse du modèle.
3. **Entraînement du modèle** : Les CNN sont entraînés sur ces images à l'aide de techniques telles que la rétro-propagation pour ajuster les poids des neurones et optimiser la capacité du modèle à classifier correctement les lésions.
4. **Évaluation et validation** : Une fois le modèle entraîné, il est testé sur un jeu de données séparé pour évaluer sa performance à l'aide de métriques telles que la précision, le rappel, la spécificité et la courbe ROC. Un bon modèle de classification devrait avoir un haut taux de précision et un faible taux de faux positifs/négatifs.

3. Techniques et Architectures Utilisées :

- **EfficientNet** : Un modèle très populaire qui optimise la performance du réseau tout en minimisant les ressources nécessaires pour le calcul. Il peut être utilisé pour classifier les lésions cutanées avec une grande précision et efficacité.
- **ResNet** : En raison de sa capacité à traiter des réseaux très profonds grâce aux blocs résiduels, ResNet est utilisé pour classer des lésions cutanées complexes en permettant une meilleure gestion des gradients.
- **Inception** : Utilisé pour classifier des lésions cutanées dans des images où les caractéristiques peuvent être très variées, grâce à l'utilisation de filtres de différentes tailles dans les couches de convolution.
- **Xception** : Basé sur l'architecture d'Inception, mais avec des convolutions séparables en profondeur, Xception a montré des résultats prometteurs dans la classification des lésions cutanées.

2.10.6 Avantages et Limites de l'Apprentissage Profond dans la Dermatologie :

L'apprentissage profond (deep learning) a connu un grand succès dans divers domaines de la médecine, et particulièrement dans la dermatologie, notamment pour la détection et la classification des lésions cutanées. Cependant, bien que cette technologie ait des avantages considérables, elle présente aussi des limites. Voici une analyse détaillée des avantages et des limites de l'apprentissage profond dans ce domaine.

2.10.6.1 Avantages de l'Apprentissage Profond dans la Dermatologie :

1. Haute Précision et Performance :

- Les modèles d'apprentissage profond, comme les réseaux de neurones convolutifs (CNN), ont montré qu'ils peuvent surpasser les dermatologues dans certains cas de classification d'images cutanées, notamment pour détecter des cancers de la peau (par exemple, le mélanome).
- Des études montrent que les CNN peuvent atteindre des performances proches ou égales à celles des experts humains en termes de précision, en particulier pour les lésions bénignes et malignes.

2. Analyse Automatisée :

- Les réseaux de neurones peuvent automatiquement extraire les caractéristiques les plus pertinentes des images cutanées, comme la texture, la couleur, la forme des lésions, sans intervention humaine. Cela permet une classification rapide et objective.
- Cette capacité d'automatisation permet de réduire les charges de travail des dermatologues et de les aider à se concentrer sur des cas plus complexes.

3. Détection Précoce du Cancer de la Peau :

- L'apprentissage profond permet de détecter des anomalies subtiles qui peuvent être difficiles à repérer à l'œil nu, contribuant ainsi à un diagnostic précoce du cancer de la peau.
- La détection précoce améliore le taux de survie des patients, car les cancers cutanés détectés tôt ont de meilleures chances de guérison.

4. Accessibilité Accrue :

- L'intelligence artificielle, utilisée dans des applications mobiles ou des systèmes de télédermatologie, permet aux patients, notamment dans des régions rurales ou sous-développées, d'obtenir des diagnostics fiables sans avoir besoin d'un dermatologue sur place.
- Cela réduit les inégalités en matière d'accès aux soins dermatologiques.

5. Réduction des Erreurs Humaines :

- L'utilisation des modèles d'apprentissage profond peut réduire les erreurs de diagnostic causées par la **fatigue** ou les **biais** humains, en fournissant une évaluation systématique et objective des images cutanées.

2.10.6.2 Limites de l'Apprentissage Profond dans la Dermatologie :

1. Dépendance à la Qualité des Données :

- Les performances des modèles d'apprentissage profond dépendent fortement de la qualité des données d'entrée. Des images floues, de mauvaise résolution, ou mal étiquetées peuvent entraîner des erreurs dans la classification.
- Les modèles sont sensibles aux données de mauvaise qualité et ne peuvent pas apprendre efficacement si les images sont incomplètes ou incorrectes.

2. Biais des Données :

- Un modèle d'apprentissage profond peut apprendre des biais présents dans les données d'entraînement. Par exemple, si le modèle est formé principalement sur des images de personnes de type ethnique particulier, il pourrait être moins performant sur des populations issues d'autres groupes ethniques.
- Cela peut limiter la généralisation des modèles, ce qui est particulièrement problématique dans des contextes cliniques diversifiés.

3. Difficulté d'Interprétation (Boîte Noire) :

- Les modèles d'apprentissage profond sont souvent considérés comme des boîtes noires, ce qui signifie qu'il est difficile de comprendre comment ou pourquoi une décision a été prise.
- En dermatologie, où l'explication des décisions de diagnostic est cruciale, ce manque d'interprétabilité peut limiter l'acceptation de ces modèles par les cliniciens, qui peuvent hésiter à les adopter sans comprendre leur logique de fonctionnement.

4. Besoin de Grandes Quantités de Données :

- Pour entraîner des modèles de deep learning performants, une grande quantité de données annotées est nécessaire. En dermatologie, cela représente un défi, car l'annotation des données (étiquetage des lésions par des dermatologues experts) est coûteuse et chronophage.
- De plus, obtenir un ensemble de données diversifié et équilibré est difficile, ce qui peut affecter la capacité du modèle à généraliser à de nouveaux cas.

5. Complexité Computationnelle :

- L'entraînement de modèles d'apprentissage profond nécessite des ressources de calcul importantes (GPU, grandes capacités de stockage), ce qui peut être coûteux et difficile à mettre en œuvre dans certains environnements cliniques.
- De plus, l'utilisation des modèles sur des appareils mobiles ou des plateformes ayant des ressources limitées peut poser des défis en termes de latence et de consommation d'énergie.

6. Régulation et Conformité :

- En dermatologie, les décisions de diagnostic doivent être conformes à des réglementations strictes en matière de santé. Les modèles d'apprentissage profond doivent être rigoureusement validés et certifiés avant d'être utilisés dans des environnements cliniques, ce qui peut prendre beaucoup de temps et de ressources.
- La question de la responsabilité (qui est responsable si le modèle fait une erreur de diagnostic) reste également un défi juridique.

7. Adaptation aux Changements de Données :

- Les modèles peuvent devenir obsolètes si les conditions ou les types de lésions cutanées évoluent avec le temps. Cela nécessite un entraînement continu pour maintenir la pertinence et la précision des modèles.
- Le domaine de la dermatologie évolue constamment avec de nouveaux types de lésions et des traitements en constante évolution, ce qui complique l'adaptation des modèles.

Avantage	limite
Haute précision et performances exceptionnelles	Dépendance à la qualité et diversité des données
Analyse automatique et rapide des lésions cutanées	Biais des données d'entraînement
Détection précoce du cancer de la peau	Difficulté d'interprétation (boîte noire)
Accessibilité accrue, même dans des zones isolées	Besoin de grandes quantités de données
Réduction des erreurs humaines	Complexité computationnelle et coût élevé

2.1 Les avantages et les limites de l'apprentissage profond dans la dermatologie

2.10.7 Défis et Perspectives de l'IA en Médecine Dermatologique :

2.10.7.1 Défis :

1. Biais dans les données :

- Les bases de données utilisées pour entraîner les modèles d'IA en dermatologie manquent parfois de diversité, notamment en termes de types de peau et de conditions pathologiques. Cela peut entraîner des inégalités dans les résultats pour les patients sous-représentés.
- La sous-représentation des peaux foncées dans les ensembles de données peut réduire la précision des diagnostics pour ces groupes.

2. Interprétabilité des modèles :

- Les systèmes d'IA, comme les réseaux de neurones convolutifs (CNN), sont souvent perçus comme des "boîtes noires". L'absence de transparence sur la façon dont une décision est prise limite leur adoption clinique

3. Réglementation et éthique :

- Les cadres juridiques et éthiques ne sont pas encore complètement adaptés à l'utilisation de l'IA, notamment en matière de confidentialité des données des patients et de responsabilité en cas d'erreur.

4. Acceptation clinique :

- Les dermatologues peuvent hésiter à utiliser des outils d'IA s'ils estiment que ces derniers pourraient remplacer leur expertise ou s'ils n'ont pas confiance dans leur fiabilité.

2.10.7.2 Perspectives :

1. Amélioration des diagnostics :

- L'IA, notamment les CNN, peut offrir des outils précis pour détecter et classer les lésions cutanées, ce qui améliore la détection précoce de maladies comme le cancer de la peau.

2. Personnalisation des traitements :

- Les modèles d'IA pourraient permettre des soins dermatologiques plus personnalisés en intégrant les données spécifiques au patient, telles que le génome et les antécédents médicaux.

3. Suivi à distance :

- Les applications d'IA combinées à des dispositifs portables pourraient permettre un suivi en temps réel des patients atteints de maladies chroniques, réduisant ainsi la charge pour les systèmes de santé.

4. Accès élargi aux soins :

- L'intégration de l'IA dans des plateformes accessibles pourrait démocratiser les soins dermatologiques, notamment dans les régions sous-médicalisées.

L'IA en dermatologie offre des opportunités immenses pour améliorer les diagnostics, la prise en charge et le suivi des patients. Toutefois, pour exploiter tout son potentiel, il est crucial d'aborder les biais de données, d'améliorer l'interprétabilité des modèles et de renforcer la confiance des cliniciens grâce à des cadres éthiques et réglementaires adaptés.

2.10.8 Enjeux éthique et considération réglementaire :

L'intégration de l'intelligence artificielle (IA) dans la dermatologie soulève des défis éthiques et réglementaires essentiels à considérer pour garantir une utilisation équitable, sûre et efficace.

2.10.8.1 Enjeux Éthiques :

1. Biais et Équité :

- Les algorithmes d'IA dépendent des données sur lesquelles ils sont entraînés. Si ces données ne reflètent pas la diversité des populations (par exemple, différents types de peau), les diagnostics peuvent être biaisés. Cela peut conduire à des erreurs médicales ou à des inégalités dans la qualité des soins.

2. Transparence et Explicabilité :

- Les modèles d'IA, souvent qualifiés de "boîtes noires", rendent difficile pour les cliniciens et les patients de comprendre comment un diagnostic a été atteint. Cette opacité peut nuire à la confiance et compliquer l'acceptation clinique.

3. Consentement et Utilisation des Données :

- L'entraînement des algorithmes nécessite de vastes bases de données d'images et d'informations médicales. Il est crucial de garantir que ces données soient collectées et utilisées avec le consentement éclairé des patients, tout en respectant leur vie privée.

4. Responsabilité en Cas d'Erreur :

- Lorsque l'IA se trompe, la responsabilité n'est pas toujours claire : revient-elle au développeur de l'algorithme, au fournisseur de données, ou au clinicien qui l'a utilisé.

5. Relation Médecin-Patient :

- L'utilisation de l'IA peut modifier la dynamique traditionnelle entre médecin et patient. Une confiance excessive dans les systèmes d'IA pourrait réduire le rôle du jugement clinique humain.

2.10.8.2 Considérations Réglementaires :

1. Validation des Algorithmes :

- Les systèmes d'IA doivent être soumis à des tests rigoureux avant leur adoption clinique, y compris des études cliniques contrôlées pour prouver leur efficacité et leur sécurité.

2. Normes Internationales :

- L'absence d'harmonisation des réglementations internationales pose un défi pour les développeurs de solutions d'IA. Des organismes comme la FDA (États-Unis) et le marquage CE (Europe) établissent des cadres pour réguler ces technologies, mais ces cadres varient.

3. Mise à Jour et Surveillance Continue :

- Les modèles d'IA doivent être continuellement surveillés et mis à jour pour s'assurer qu'ils restent efficaces face à l'évolution des données médicales et démographiques.

4. Certification et Formation des Utilisateurs :

- Les cliniciens doivent être formés pour comprendre les capacités et les limites des outils d'IA, et ces outils doivent obtenir des certifications pour leur utilisation clinique.

2.10.8.3 Solutions et Initiatives :

1. Diversité des Données :

- Développer des bases de données représentatives de différentes populations pour limiter les biais et améliorer la robustesse des modèles.

2. Algorithmes Explicables (XAI) :

- Encourager le développement de modèles d'IA explicables pour permettre aux cliniciens de mieux comprendre et valider les diagnostics.

3. Collaboration Multi-sectorielle :

- Associer régulateurs, cliniciens, patients et développeurs pour établir des cadres éthiques et réglementaires solides.

2.10.9 Les défis liés aux biais de données et aux interprétations des modèles IA :

L'utilisation de l'IA, notamment dans des domaines sensibles comme la médecine, est confrontée à deux défis majeurs : les biais de données et les limitations dans l'interprétation des modèles. Ces problèmes peuvent réduire la fiabilité et l'équité des systèmes d'IA et entraver leur adoption.

2.10.9.1 Biais de Données :

Origine des biais :

- **Manque de diversité dans les données :**
Les ensembles de données utilisés pour entraîner les modèles d'IA ne sont pas toujours représentatifs de la population cible. Par exemple, en dermatologie, les modèles sont souvent entraînés sur des images de peaux claires, ce qui peut limiter leur précision pour les peaux foncées.
- **Annotations erronées :**
Les erreurs ou les incohérences dans l'étiquetage des données peuvent induire des biais dans les prédictions des modèles.
- **Biais systémique :**
Les données collectées peuvent refléter des inégalités systémiques existantes dans les soins de santé, amplifiant ces inégalités lorsqu'elles sont intégrées dans des modèles.

Impact des biais :

- Les biais peuvent entraîner une inexactitude diagnostique, affectant plus gravement les groupes sous-représentés.
- Ils réduisent la confiance dans les systèmes d'IA, en particulier lorsqu'ils sont perçus comme discriminatoires ou injustes.

Interprétation des Modèles (Boîte Noire) :

Problèmes d'interprétabilité :

- **Complexité des modèles :**
Les réseaux de neurones, notamment les réseaux convolutifs, fonctionnent comme des "boîtes noires" en raison de leur structure hautement non linéaire. Cela rend difficile de comprendre pourquoi un modèle a produit une certaine prédiction.
- **Décisions non explicables :**
Dans des contextes critiques comme la médecine, l'absence d'explications claires sur le fonctionnement d'un modèle peut entraîner une réticence à adopter ces systèmes.

Conséquences de l'opacité :

- Les cliniciens peuvent hésiter à utiliser les systèmes d'IA si les résultats ne sont pas compréhensibles ou justifiables.
- L'incapacité à identifier et corriger les erreurs limite l'amélioration des modèles.

Solutions Potentielles :

Pour les biais de données :

- **Collecte de données diversifiées :**
Créer des bases de données représentatives de diverses populations, incluant différents groupes ethniques, géographiques, et démographiques.
- **Techniques de débiaisement :**
Utiliser des algorithmes qui détectent et corrigent les biais dans les ensembles de données et pendant l'entraînement des modèles.
- **Collaboration interdisciplinaire :**
Associer des experts en éthique, cliniciens et développeurs pour identifier et réduire les biais dans les systèmes.

Pour l'interprétabilité :

- **Développement de modèles explicables (XAI - eXplainable AI) :**
Concevoir des systèmes qui fournissent des explications compréhensibles pour les humains sur leurs prédictions.
- **Visualisation des activations :**
Utiliser des techniques comme les Grad-CAM (Gradient-weighted Class Activation Mapping) pour montrer quelles parties des données d'entrée influencent le plus les prédictions.
- **Formation des utilisateurs :**
Éduquer les cliniciens sur les capacités et les limites des modèles d'IA pour renforcer leur confiance.

2.10.10 Le future de l'IA dans le diagnostic dermatologique et le suivi des patients :

L'intelligence artificielle (IA) offre des perspectives prometteuses pour révolutionner le domaine de la dermatologie. Les avancées technologiques, combinées à l'amélioration des données et des algorithmes, ouvrent de nouvelles possibilités pour le diagnostic précoce, la personnalisation des traitements, et le suivi des patients.

1. Diagnostic Dermatologique Automatisé :

- **Précision accrue :**
L'utilisation de modèles avancés comme les réseaux de neurones convolutifs (CNN) pour analyser des images dermatologiques permet d'identifier les maladies de la peau avec une précision équivalente, voire supérieure, à celle des dermatologues expérimentés.
- **Accessibilité :**
L'IA rend le diagnostic accessible dans des régions éloignées ou sous-équipées en permettant l'analyse via des applications mobiles ou des dispositifs portables.

- **Détection précoce :**

Les modèles d'IA permettent de repérer des anomalies cutanées avant qu'elles ne deviennent visibles pour l'œil humain, augmentant ainsi les chances de traitement précoce, en particulier pour des maladies graves comme le mélanome

2. Suivi et Gestion Personnalisée des Patients :

- **Surveillance continue :**

Les dispositifs connectés (comme les capteurs portables) intégrés à des systèmes d'IA peuvent suivre l'évolution des maladies cutanées ou la réponse au traitement, alertant les patients et les cliniciens en cas de changements significatifs.

- **Personnalisation des traitements :**

Les modèles d'IA peuvent analyser les caractéristiques spécifiques de chaque patient pour proposer des traitements dermatologiques adaptés, optimisant les résultats et réduisant les effets secondaires.

- **Engagement des patients :**

L'IA peut être utilisée pour éduquer les patients sur les soins de leur peau et les encourager à suivre des régimes thérapeutiques, améliorant ainsi l'adhérence au traitement.

3. Perspectives Émergentes :

- **Applications de télémédecine :**

L'intégration de l'IA dans des plateformes de télémédecine permettra aux patients d'obtenir des diagnostics initiaux ou des conseils directement depuis leur domicile, réduisant ainsi le besoin de consultations en personne.

- **Modèles explicables et éthiques :**

Les efforts pour rendre l'IA plus transparente et explicable contribueront à renforcer la confiance des cliniciens et des patients, augmentant son adoption.

- **Approches multi classification :**

L'évolution vers des modèles capables de classifier plusieurs types de lésions simultanément et de fournir des probabilités diagnostiques précises permettra des diagnostics plus complets et rapides.

2.11 Conclusion :

Dans ce chapitre on a parlé tout d'abord de l'intelligence artificielle et du deep learning sa définition et importance et en particulier l'utilisation de deep learning pour la prédiction du cancer de la peau. Nous avons également parlé des réseaux de neurones convolutifs CNN et de leur architecture.

3 Chapitre 3 :Le développement du model intelligent

3.1 Introduction

Dans ce chapitre, nous présentons le processus de développement et les résultats de nos modèles d'apprentissage profond utilisant les techniques CNN (Convolutional Neural Networks) pour l'identification des maladies dermatologiques à partir d'images de lésions cutanées.

Les maladies dermatologiques constituent un enjeu majeur en matière de santé publique, avec des répercussions significatives sur la qualité de vie des patients. Le diagnostic précoce de ces maladies est crucial pour prévenir leur progression et réduire les risques de complications graves, comme le cancer de la peau. Cependant, divers facteurs limitent l'accès à un diagnostic précis : le manque d'expertise dermatologique, les coûts élevés des consultations spécialisées, et la variabilité des signes cliniques selon les types de peau et les caractéristiques individuelles.

Face à cette problématique, il est essentiel de mettre en place un système automatisé et intelligent capable de détecter avec précision les maladies dermatologiques à partir d'images de lésions cutanées. Une telle solution pourrait compléter l'expertise médicale en améliorant l'accessibilité et la rapidité des diagnostics.

Pour répondre à ces défis, nous avons développé une approche novatrice basée sur les modèles d'apprentissage profond, en particulier les **Convolutional Neural Networks (CNN)**. Ces modèles permettent d'analyser les images dermatoscopiques et d'identifier les maladies de la peau qui y sont associées. En utilisant le jeu de données **HAM10000**, qui contient des images de lésions classées dans 7 catégories de maladies dermatologiques, nous avons conçu et entraîné un modèle capable de distinguer ces classes avec un haut niveau de précision.

Notre approche prend en compte les spécificités de chaque type de lésion (comme les mélanomes, les kératoses bénignes ou les carcinomes basocellulaires) et utilise des techniques de transfert d'apprentissage pour tirer parti de réseaux pré-entraînés tels que **MobileNetV2**. Ce choix permet d'améliorer les performances tout en optimisant les ressources nécessaires à l'entraînement.

Ainsi, ce travail s'inscrit dans une démarche d'innovation technologique, visant à apporter une solution concrète et accessible pour assister les professionnels de santé dans le diagnostic des maladies dermatologiques.

3.2 Travail Réalisé :

3.2.1 La base de données :

1. HAM10000 (Human Against Machine with 10000 training images):

HAM10000 est l'une des bases de données les plus connues dans le domaine de la dermatologie. Elle a été utilisée pour former et tester des modèles d'apprentissage profond et d'intelligence artificielle pour le diagnostic des maladies de la peau.

-Détails de la base de données :

- **Nombre d'images :** 10 000 images.
- **Catégories de lésions :** Elle couvre 7 types principaux de lésions dermatologiques, dont le mélanome, les nævus (grain de beauté), et des lésions bénignes et malignes.
- **Format des données :** Les images sont en haute résolution et accompagnées de métadonnées sur l'étiologie et les caractéristiques cliniques des lésions.
- **But :** Elle sert à la classification des images dermatologiques, avec des annotations pour l'étiologie de chaque lésion.
- **Usage :** Cette base est utilisée pour développer et tester des modèles de classification d'images de la peau, avec une attention particulière à l'amélioration de l'exactitude des diagnostics.

-Types de lésions dans HAM10000 :

- Mélanome.
- Nævus bénin.
- Nævus atypique.
- Kératose séborrhéique.
- Dermato fibrome.
- Carcinome basocellulaire (BCC).
- Carcinome épidermoïde (SCC).

-Accessibilité :

- **Lien d'accès :** Cette base de données est disponible sur Kaggle pour les chercheurs et les développeurs.

3.2.2 Répartition des données :

Pour entraîner et évaluer notre modèle, le jeu de données a été divisé en trois ensembles distincts :

- **Ensemble d'entraînement (80 % des données)** : Utilisé pour ajuster les paramètres du modèle. Cet ensemble contient **8 012 images** réparties stratégiquement pour respecter la distribution des classes.
- **Ensemble de validation (10 % des données)** : Composé de **1 002 images**, il est utilisé pendant l'entraînement pour suivre les performances du modèle et ajuster les hyperparamètres (par exemple, le taux d'apprentissage).
- **Ensemble de test (10 % des données)** : Composé de **1 001 images**, cet ensemble est utilisé pour évaluer la performance finale du modèle après l'entraînement.

La division des données a été effectuée de manière stratifiée afin de conserver la proportion de chaque classe dans chaque ensemble. Cette approche garantit que même les classes minoritaires comme **Dermatofibroma (DF)** ou **Vascular Lesion (VASC)** sont correctement représentées pendant l'entraînement et le test.

3.2.3 Architecture du Modèle, Processus d'Entraînement et Environnement de Travail :

1. Environnement de Travail :

L'ensemble du développement et de l'entraînement du modèle a été réalisé dans l'environnement cloud **Google Colab**, en raison de ses nombreux avantages :

- **Accélérateurs matériels** : Google Colab offre un accès gratuit à des GPU (Graphics Processing Units) comme Tesla K80, T4 ou P100, indispensables pour accélérer les calculs liés à l'entraînement des modèles d'apprentissage profond.
- **Librairies intégrées** : Colab intègre directement TensorFlow, Keras, et d'autres bibliothèques essentielles pour le Machine Learning.
- **Compatibilité avec Google Drive** : Les fichiers du jeu de données HAM10000 ont été facilement importés et sauvegardés depuis Google Drive.

Configuration utilisée dans Google Colab :

- **Processeur** : 2 cœurs virtuels.
- **Mémoire vive (RAM)** : 12 Go.
- **Accélérateur matériel** : GPU Tesla T4 (via l'option Runtime > Change Runtime Type > GPU).

Ces ressources ont permis de réduire considérablement le temps d'entraînement du modèle tout en assurant une exécution fluide des scripts.

3.2.4 Architecture du Modèle :

Base pré-entraînée : MobileNetV2 :

L'architecture du modèle est basée sur **MobileNetV2**, un réseau convolutif (CNN) léger, spécialement conçu pour les appareils embarqués et les environnements nécessitant des calculs rapides. MobileNetV2 se distingue par :

- **Des convolutions depthwise separables** : Réduction du nombre de calculs nécessaires en séparant les opérations spatiales et canaux.
- **Des blocs résiduels inversés (Inverted Residual Blocks)** : Ils permettent une meilleure propagation des gradients lors de l'entraînement.
- **Un goulot linéaire (Linear Bottleneck)** : Réduction des dimensions des couches intermédiaires pour diminuer la complexité du modèle.

Le modèle a été initialisé avec les poids pré-entraînés sur **ImageNet**, une base de données contenant plus de 14 millions d'images réparties dans 1 000 catégories, ce qui lui permet de disposer de connaissances générales sur les caractéristiques visuelles.

3.2.5 Personnalisation pour HAM10000 :

Pour adapter MobileNetV2 à la classification des 7 classes de lésions dermatologiques du jeu HAM10000, des couches supplémentaires ont été ajoutées au-dessus du réseau de base. L'architecture finale comprend :

1. **MobileNetV2 sans les couches supérieures** : La partie convolutionnelle du réseau pré-entraîné (extraction des caractéristiques) est utilisée.
2. **GlobalAveragePooling2D** : Réduction spatiale des caractéristiques extraites.
3. **Dropout (0.5)** : Ajout de régularisation pour éviter le surapprentissage.
4. **Dense Layer avec activation Softmax** : Une couche entièrement connectée avec 7 neurones pour produire les probabilités des 7 classes de sortie.

Composant	Description
MobileNetV2	Base pré-entraînée pour extraire les caractéristiques
GlobalAveragePooling2D	Réduction spatiale
Dropout (0.5)	Régularisation pour réduire l'overfitting
Dense(7 neurones , softmax)	Prédiction des probabilités pour 7 classes


3.1 Ham 10000

3.2.6 Processus d'Entraînement :

A / Prétraitement des Données :

Pour que les données soient adaptées à l'entraînement, plusieurs étapes de prétraitement ont été réalisées :

1. **Redimensionnement** : Toutes les images du jeu HAM10000 ont été redimensionnées en 224x224 pixels, afin de correspondre à l'entrée attendue par MobileNetV2.
2. **Normalisation** : Les valeurs des pixels (0-255) ont été normalisées entre 0 et 1 pour accélérer la convergence.
3. **Augmentation des données** : Des techniques de transformations aléatoires ont été appliquées aux images d'entraînement pour améliorer la robustesse du modèle :
 - Rotation, zoom, translation, retournement horizontal.



3.1 Exemple de DTTA Augmentation

Pourquoi la Data Augmentation est importante ?

- **Augmente la diversité des données** : Réduit l'overfitting en générant des variations artificielles à partir des images existantes.
- **Rend le modèle plus robuste** : Le modèle apprend à gérer des variations naturelles comme la rotation, le zoom ou les décalages, ce qui améliore ses performances sur des données réelles.
- **Solution au déséquilibre des classes** : Certaines classes ayant peu d'images peuvent être artificiellement enrichies grâce à l'augmentation.

B/ Phases d'Entraînement :

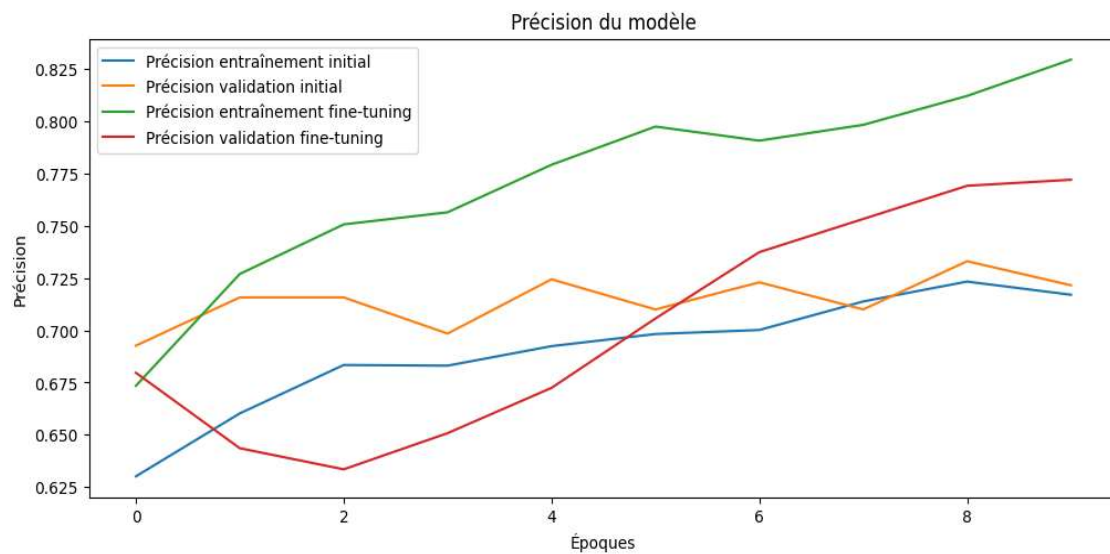
L'entraînement s'est déroulé en **deux phases** pour maximiser les performances tout en minimisant les risques de sur apprentissage.

a. Phase 1 : Entraînement des couches supérieures :

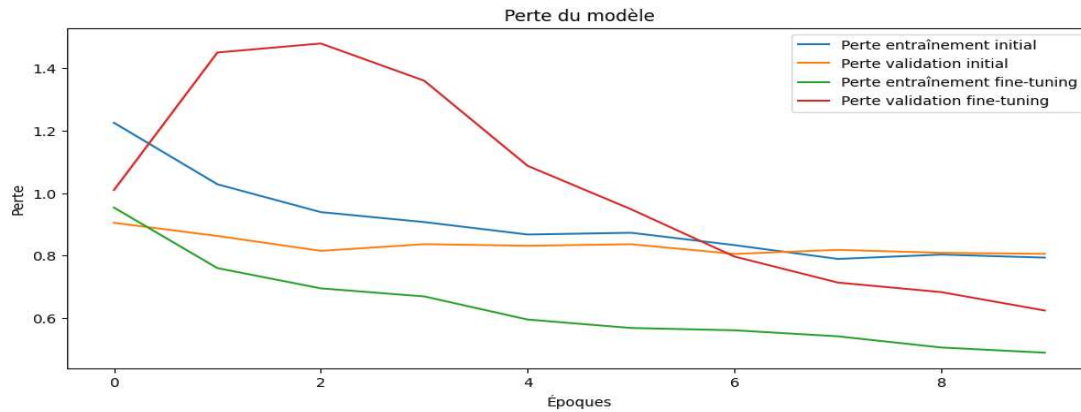
- Les poids des couches de MobileNetV2 ont été gelés pour préserver les caractéristiques générales apprises sur ImageNet.
- Seules les couches ajoutées ont été entraînées.
- Optimiseur : Adam avec un taux d'apprentissage de 0.001.
- Critère d'arrêt : L'entraînement s'arrêtait automatiquement si la perte de validation ne s'améliorait plus après 5 époques.

b. Phase 2 : Fine-tuning (affinage des couches profondes)

- Les dernières couches de MobileNetV2 ont été dégelées pour affiner les poids spécifiques à HAM10000.
- Le taux d'apprentissage a été réduit à 0.0001 pour éviter de modifier trop brutalement les poids existants.



3.2 L'évolution de la précision du modèle



3.3 Perte du modèle

Les graphiques montrent clairement que le fine-tuning est une étape cruciale pour améliorer les performances du modèle. Voici les principaux points à retenir :

1. **Précision d'entraînement** : Elle s'améliore considérablement lors du fine-tuning.
2. **Précision de validation** : Le fine-tuning permet de réduire l'écart entre les performances d'entraînement et de validation, démontrant une meilleure capacité de généralisation.

3.3 Résultats et Discussion :

Dans cette section, nous analysons les performances du modèle à partir des métriques d'évaluation, en se basant sur la **matrice de confusion** et le **rapport de classification**.

3.3.1 Matrice de Confusion :

La matrice de confusion fournie montre la répartition des prédictions correctes et incorrectes du modèle pour chaque classe. Voici la matrice analysée :

	kiec	bcc	bk1	df	mel	nv	vasc
akiec	3	8	12	1	1	0	0
bcc	1	21	5	0	1	10	0
bk1	0	3	65	0	4	12	0
df	0	0	3	3	1	2	0
mel	1	1	18	0	29	41	0
nv	0	4	25	0	8	474	0
vasc	0	2	0	0	0	4	6

3.3.2 Interprétation de la matrice :

- **Classe akiec** : Seulement **3 prédictions correctes sur 25** échantillons, ce qui montre que le modèle a des difficultés à reconnaître cette classe. Elle est souvent confondue avec bkl et bcc.
- **Classe bcc** : Une précision modérée, avec **21 prédictions correctes sur 38**. Les confusions les plus fréquentes se font avec akiec et nv.
- **Classe bkl** : Le modèle performe relativement bien, avec **65 prédictions correctes sur 84**. Certaines erreurs sont attribuées aux classes mel et nv.
- **Classe df** : Très peu d'échantillons (**9**) pour cette classe, avec seulement **3 prédictions correctes**, ce qui indique que la classe est sous-représentée.
- **Classe mel** : La performance est moyenne avec **29 prédictions correctes sur 90**, tandis que beaucoup d'échantillons sont mal classifiés en bkl ou nv.
- **Classe nv** : Le modèle excelle dans la reconnaissance de cette classe avec **474 prédictions correctes sur 511**, ce qui est la meilleure performance.
- **Classe vasc** : Bien que les échantillons soient peu nombreux (**12**), le modèle atteint une performance acceptable avec **6 prédictions correctes**.

3.3.3 Rapport de Classification :

Le rapport de classification est un outil puissant pour évaluer la performance d'un modèle de classification. Il permet d'identifier les classes où le modèle performe bien et celles où il présente des lacunes. Cela aide à ajuster les stratégies, comme l'équilibrage des données, l'amélioration du modèle ou l'utilisation de techniques de **Data Augmentation** pour améliorer les résultats sur les classes faibles.

Le rapport de classification présente des métriques clés : **précision**, **rappel** et **f1-score** pour chaque classe.

Classe	Précision	Rappel	F1-Score	Support
akiec	0.60	0.12	0.20	25
bcc	0.54	0.55	0.55	38
bkl	0.51	0.77	0.61	84
df	0.75	0.33	0.46	9
mel	0.66	0.32	0.43	90
nv	0.87	0.93	0.90	511
vasc	1.00	0.50	0.67	12

3.4 Le rapport de classification

1. Précision (Precision) :

- **Définition** : La précision indique la proportion des prédictions positives qui sont réellement correctes pour une classe donnée.
- **Formule** :

$$\text{Précision} = \frac{\text{Vrai Positif (VP)}}{\text{Vrai Positif (VP)} + \text{Faux Positif (FP)}}$$

- **Interprétation** :
Une précision élevée signifie que le modèle fait très peu de prédictions fausses pour cette classe.
Par exemple, pour la classe vasc, une précision de **100 %** signifie que toutes les prédictions faites pour cette classe sont correctes.

2. Rappel (Recall) ou Sensibilité :

- **Définition** : Le rappel mesure la capacité du modèle à trouver tous les exemples pertinents pour une classe donnée.
- **Formule** :

$$\text{Rappel} = \frac{\text{Vrai Positif (VP)}}{\text{Vrai Positif (VP)} + \text{Faux Négatif (FN)}}$$

- **Interprétation** :
Un rappel élevé signifie que le modèle a réussi à identifier la plupart des exemples appartenant à cette classe.
Par exemple, pour la classe bkl, un rappel de **77 %** signifie que 77 % des exemples réels de cette classe ont été correctement identifiés.

Métriques globales :

- **Accuracy globale** : **82 %** sur l'ensemble de test.
- **Moyenne pondérée (Weighted Avg)** :
 - **Précision** : **82 %**
 - **Rappel** : **82 %**
 - **F1-Score** : **82 %**

3. F1-Score :

- **Définition** : Le **F1-Score** est la moyenne harmonique entre la **précision** et le **rappel**. Il offre un équilibre entre ces deux métriques.
- **Formule** :

$$\text{F1-Score} = 2 \times \frac{\text{Précision} \times \text{Rappel}}{\text{Précision} + \text{Rappel}}$$

- **Interprétation :**

Le **F1-Score** est particulièrement utile lorsque les classes sont déséquilibrées. Une valeur élevée indique un bon compromis entre précision et rappel.

Exemple : Pour la classe mel, un F1-Score de **0.43** montre qu'il y a des lacunes dans les prédictions.

3.3.4 Discussion des Résultats :

1. Déséquilibre des classes :

Les résultats montrent que la performance du modèle est fortement influencée par le déséquilibre des données. Par exemple, la classe nv (majoritaire) est bien prédite, tandis que les classes minoritaires, comme df ou akiec, souffrent de faibles scores.

- **Solution proposée :** Utiliser des techniques comme **la Data Augmentation** pour les classes sous-représentées afin d'améliorer leurs performances.

2. Confusions entre classes similaires :

Les classes akiec, bcc et mel présentent des caractéristiques visuelles similaires, ce qui explique les confusions du modèle.

- **Solution proposée :** Améliorer le modèle avec des approches avancées telles que **l'attention mechanism** ou utiliser un modèle pré-entraîné plus robuste (comme EfficientNet ou ResNet).

3. Précision globale :

Le modèle atteint une **précision globale de 82 %**, ce qui est encourageant pour un problème aussi complexe que la classification des lésions cutanées. Toutefois, les classes sous-performantes nécessitent des ajustements.

4. Impact du Fine-Tuning :

Les résultats observés ont bénéficié du **fine-tuning**, comme vu précédemment avec les graphiques de précision. Cette technique a permis au modèle d'améliorer sa capacité à généraliser sur les données de test.

3.4 Conclusion :

Ce chapitre a présenté le développement d'un modèle de classification des lésions cutanées basé sur l'architecture **MobileNetV2** combinée à des couches personnalisées. L'entraînement s'est déroulé en deux phases : **gel des couches** pour stabiliser l'apprentissage, suivi d'un **fine-tuning** pour affiner les performances. Grâce à l'environnement **Google Colab** et à des techniques comme la **Data Augmentation**, le modèle a atteint un **taux de reconnaissance de 82 %**.

Ce modèle alimente l'application **Dermadactor**, déployée dans un navigateur via **TensorFlow.js**, permettant une classification des lésions en temps réel. Bien que les résultats soient prometteurs, des améliorations futures restent possibles pour optimiser les performances, notamment par l'élargissement du jeu de données ou l'intégration de nouvelles techniques avancées.

4 Chapitre 4 : Présentation de L'application

4.1 Création de l'application Dermadoctor :

L'application Dermadoctor est un outil web interactif basé sur l'intelligence artificielle. Elle permet d'analyser des images de lésions cutanées pour fournir des prédictions sur leur nature (par exemple, mélanome, kératose bénigne, etc.). Cette application combine plusieurs technologies modernes pour offrir une interface intuitive et un diagnostic rapide.



4.1 Loge de L'application

4.1.1 Objectifs de l'application :

L'objectif principal de Dermadoctor est de fournir un système de classification simple, accessible en ligne, basé sur des modèles d'apprentissage automatique (Machine Learning). Les étapes incluent :

- Permettre à l'utilisateur de charger une image d'une lésion cutanée.
- Utiliser un modèle pré-entraîné de classification des maladies de la peau pour analyser cette image.
- Afficher les résultats de la prédiction sous forme de texte et de graphiques.

4.1.2 Technologies utilisées :

L'application combine plusieurs technologies clés :

a. TensorFlow.js :

- TensorFlow.js est une bibliothèque JavaScript utilisée pour exécuter des modèles d'apprentissage automatique dans le navigateur.
- Le modèle pré-entraîné est converti en format compatible avec TensorFlow.js depuis un modèle Keras/TensorFlow (Python).

- Ce modèle prend une image en entrée, la traite et renvoie une probabilité pour chaque catégorie.

b. HTML, CSS et JavaScript :

- **HTML** structure la page, permettant à l'utilisateur d'interagir avec l'application (input d'images, affichage des résultats).
- **CSS** est utilisé pour styliser l'application, la rendant visuellement attrayante et ergonomique.
- **JavaScript** gère la logique de l'application, notamment :
 - Le chargement du modèle.
 - Le prétraitement des images.
 - La prédiction et l'affichage des résultats.

c. Chart.js :

- Chart.js est utilisé pour afficher les résultats de la prédiction sous forme de graphique à barres, offrant une visualisation claire des probabilités.

d. Visual Studio Code ET Live Server:

- Visual Studio Code a été utilisé comme environnement de développement.
- Live Server a permis de simuler un serveur local pour contourner les problèmes de CORS.

4.1.3 Fonctionnalités principales :

Voici les principales fonctionnalités de l'application Dermadoctor :

a. Chargement d'une image :

- L'utilisateur peut charger une image via un champ de saisie `<input type="file">`.
- L'image est affichée dans un canvas HTML pour une prévisualisation.

b. Prétraitement de l'image :

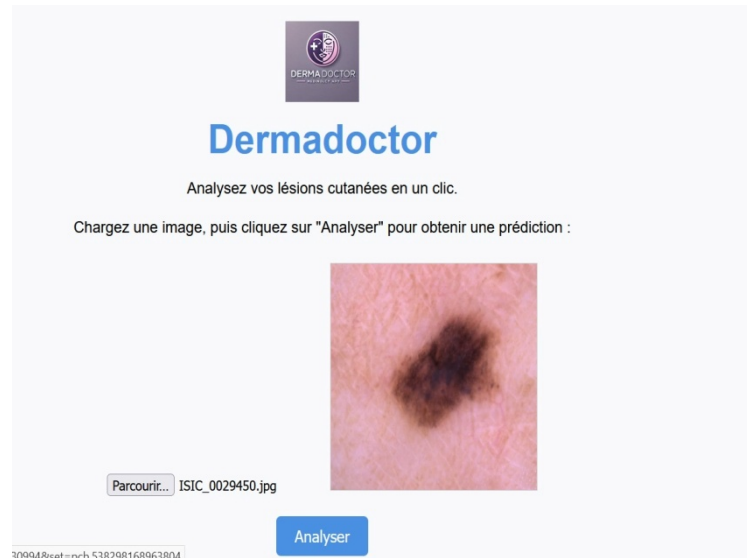
- L'image est convertie en un tenseur (un format manipulable par TensorFlow.js).
- Elle est redimensionnée à 224x224 pixels, normalisée (valeurs entre 0 et 1), et augmentée avec une dimension supplémentaire (batch size).

c. Analyse par le modèle d'IA :

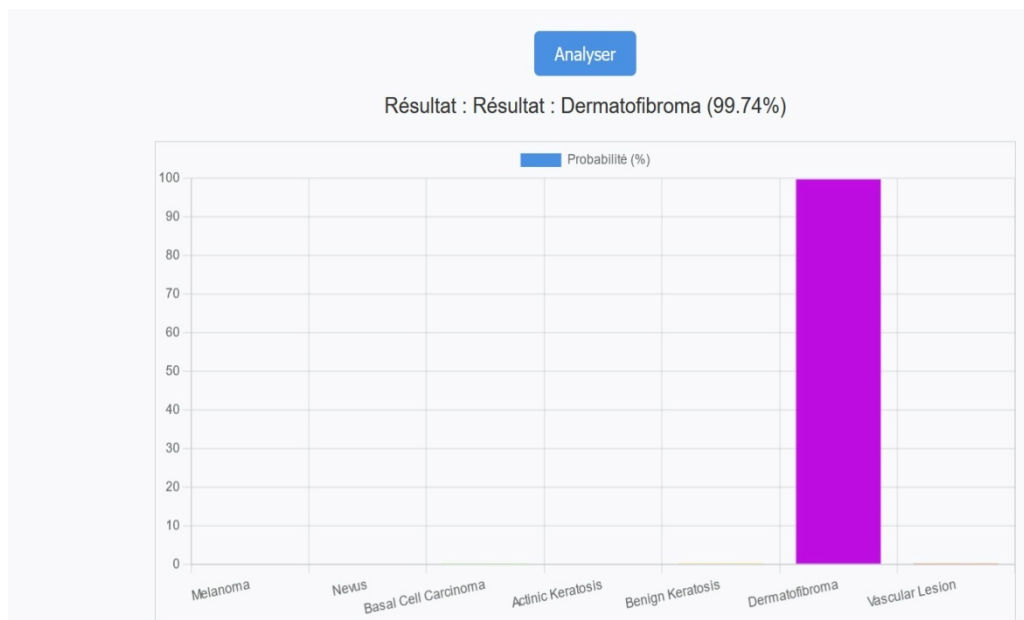
- Une fois l'image prétraitée, elle est passée au modèle TensorFlow.js via `model.predict()` pour obtenir les probabilités de chaque classe.

d. Affichage des résultats :

- Le résultat principal (classe avec la probabilité maximale) est affiché sous forme de texte (par exemple : "Mélanome détecté avec une probabilité de 85 %").
- Un graphique à barres montre les probabilités pour chaque classe, offrant une visualisation claire des résultats.



4.2 Chargement de l'image et l'affichage de résultat



4.3 Un graphique a barres montre la résultat

4.1.4 Étapes de développement :

Voici les différentes étapes qui ont été suivies pour créer l'application :

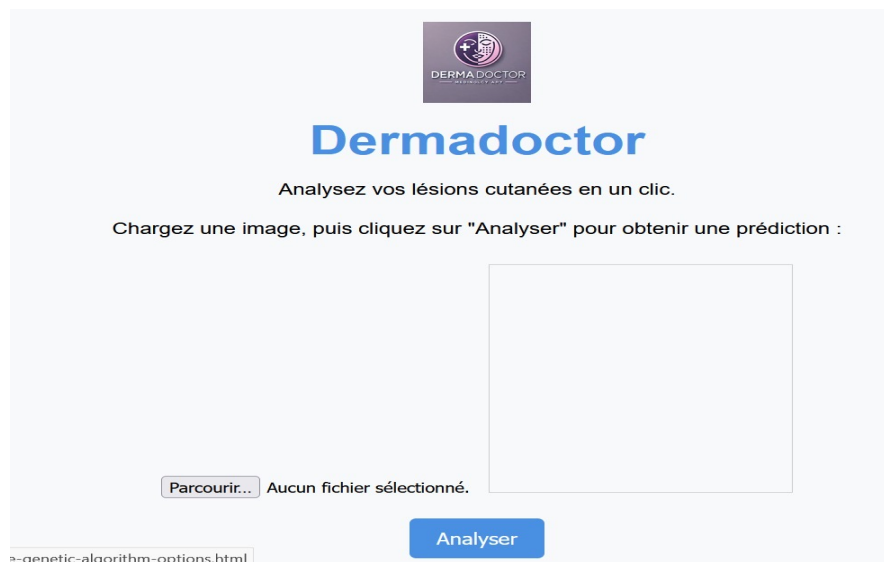
a. Préparation du modèle d'IA :

1. Le modèle d'origine a été entraîné à l'aide de **Keras/TensorFlow** (en Python) sur le jeu de données **HAM10000**.
2. Le modèle a été converti en format **TensorFlow.js** via l'outil *tensorflowjs_converter*.
3. Les fichiers *model.json* et *group1-shard*.bin* ont été inclus dans le dossier *tfjs_model/*.

b. Développement de l'interface utilisateur :

1. Un fichier *index.html* a été créé pour structurer l'interface de l'application :
 - Titre et description.
 - Champ de chargement d'image.
 - Bouton pour lancer l'analyse.
 - Zone pour afficher les résultats.
 - Un canvas pour la visualisation des graphiques avec Chart.js.

Le style a été amélioré via un fichier CSS (*style.css*) pour un rendu plus professionnel.



4.4 Implémentation de l'application

c. Implémentation de la logique de l'application :

1. Un fichier *app.js* a été créé pour gérer :
 - Le chargement du modèle TensorFlow.js.
 - Le prétraitement des images.
 - L'interaction utilisateur (bouton "Analyser").
 - L'affichage des prédictions (texte et graphiques).

Les erreurs possibles ont été gérées, par exemple :

- Vérifier que l'image est bien chargée avant de lancer une analyse.
- Afficher des messages clairs en cas d'échec.

d. Tests et débogage :

- L'application a été testée localement à l'aide de **Live Server**.
- La console du navigateur a été utilisée pour identifier et résoudre les éventuelles erreurs (CORS, chargement du modèle, etc.).

4.1.5 Organisation des fichiers :

L'application est structurée comme suit :

web-app/

|— index.html # Structure principale de l'application

|— app.js # Logique JavaScript de l'application

|— style.css # Styles CSS pour l'application

|— tfjs_model/ # Modèle TensorFlow.js

| |— model.json # Architecture du modèle

| |— group1-shard1of1.bin # Poids du modèle

|— assets/

|— Dermadoctor_logo.png # Logo de l'application

4.2 Résultats attendus :

1. L'utilisateur charge une image d'une lésion cutanée.
2. L'application traite l'image et effectue une prédiction en quelques secondes.
3. Les résultats sont affichés :
 - La classe la plus probable (par exemple : "Mélanome").
 - Un graphique à barres illustrant les probabilités pour toutes les classes.

L'interface est ergonomique et peut être utilisée directement depuis un navigateur web.

4.3 Conclusion :

Dermadoctor est une application innovante qui utilise l'intelligence artificielle et les technologies web modernes pour fournir une analyse rapide et accessible des lésions cutanées. Elle démontre l'efficacité des modèles pré-entraînés intégrés dans des applications web interactives grâce à TensorFlow.js. Cette application pourrait servir de base à des outils encore plus complets dans le domaine de la santé numérique.

Conclusion Générale et Perspectives

Dans ce mémoire, nous avons exploré une approche innovante pour l'identification des maladies dermatologiques, notamment les lésions cutanées, en utilisant des techniques avancées d'**Intelligence Artificielle** et de **Deep Learning**. En réponse aux défis posés par le diagnostic manuel, tels que les délais, les coûts élevés et les erreurs potentielles, notre étude a proposé un modèle de classification automatique basé sur une architecture performante de réseau de neurones convolutifs (CNN), avec un focus particulier sur **MobileNetV2**.

Les résultats obtenus démontrent que le **Deep Learning**, lorsqu'il est appliqué avec des techniques appropriées d'optimisation et de déploiement, peut jouer un rôle crucial dans la détection précoce des maladies dermatologiques. Cette solution offre une alternative fiable, rapide et accessible, tout en facilitant le travail des professionnels de la santé.

Perspectives

Malgré les résultats prometteurs obtenus, plusieurs axes d'amélioration peuvent être envisagés pour perfectionner ce travail et assurer son déploiement à grande échelle :

1. Amélioration des performances du modèle :

- Enrichir la base de données avec des images plus variées pour améliorer la robustesse et la généralisation du modèle.
- Expérimenter d'autres architectures de réseaux de neurones, telles que **EfficientNet** ou **ResNet**, qui pourraient offrir de meilleures performances.
- Appliquer des techniques avancées comme **l'augmentation des données conditionnelle** et **le transfert d'apprentissage sur des modèles pré-entraînés plus récents**.

2. Détection multi-étiquettes :

Certaines images peuvent présenter plusieurs types de lésions simultanément. Intégrer un modèle capable de gérer la **classification multi-étiquettes** permettrait d'élargir les capacités de détection.

3. Expérience utilisateur améliorée :

- Développer une interface plus intuitive et conviviale pour l'application web, en y ajoutant des fonctionnalités comme la génération d'un **rapport détaillé** pour chaque prédiction.
- Intégrer des outils d'explication des décisions du modèle (**Explainable AI**) pour accroître la confiance des utilisateurs.

4. Validation clinique :

Afin d'assurer la fiabilité des résultats dans un contexte réel, il est essentiel de collaborer avec des dermatologues pour valider les performances du modèle sur des **données cliniques inédites**.

5. Intégration dans un cadre médical réel :

- Développer une version mobile de l'application pour permettre son utilisation dans des zones à faible accès aux spécialistes médicaux.

- Intégrer le modèle dans des systèmes hospitaliers ou des dispositifs médicaux pour un usage quotidien par les praticiens.

6. **Aspects éthiques et légaux :**

Étudier les questions liées à la **protection des données des patients** et à la conformité avec les régulations médicales (comme le **RGPD**) est essentiel pour garantir une utilisation éthique et sécurisée de l'application.

Web graphie :

www.mayoclinic.org/diseases-conditions

<https://www.who.int/news-room/fact-sheets/detail/skin-cancers>

<https://www.nature.com/articles/nature21056>

<https://cs229.stanford.edu>

<https://www.coursera.org/specializations/deep-learning>

<https://www.deeplearningbook.org/>

<https://www.ibm.com/fr-fr/topics/artificial-intelligence>

<https://www.tensorflow.org/tutorials/images/cnn>

<https://www.nature.com/articles/s41586-019-1313-3>

<https://www.microsoft.com/en-us/research/publication/deep-residual-learning-for-image-recognition/>

https://keras.io/guides/transfer_learning/

<https://ai.googleblog.com/2017/06/mobilenets-accelerating-deep-networks.html>

<https://arxiv.org/abs/1505.04597>

<https://pubmed.ncbi.nlm.nih.gov/>

<https://www.isic-archive.com/>

<https://arxiv.org/abs/1905.11946>

<https://www.kaggle.com/datasets>

<https://www.expert.ai/blog/convolutional-neural-networks/>

<https://www.tensorflow.org/tutorials/images/cnn>

https://www.tensorflow.org/api_docs/python/tf/keras/applications/MobileNetV2

Bibliographie :

Bologna, J. L., Schaffer, J. V., & Cerroni, L. (2018). *Dermatology* (4th ed.). Elsevier.

Garbe, C., & Leiter, U. (2009). "Melanoma epidemiology and trends." *Clinics in Dermatology*, 27(1)

Habif, T. P. (2015). *Clinical Dermatology: A Color Guide to Diagnosis and Therapy* (6th ed.). Elsevier

Article : Turing, A.M. (1950). *Computing Machinery and Intelligence*. *Mind*, 59, 433-460

Livre : *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow* par **Aurélien Géron**, éditions O'Reilly.

Deep Learning par **Ian Goodfellow, Yoshua Bengio, et Aaron Courville**, MIT Press.

Article : LeCun, Y., Bengio, Y., & Hinton, G. (2015). *Deep Learning*. *Nature*, 521(7553), 436–444.

Livre : *Neural Networks and Deep Learning* par **Michael Nielsen**.

Goodfellow, Ian, Bengio, Yoshua, & Courville, Aaron (2016).

Lecun, Yann, et al. (2016). "*Convolutional Networks and Applications*." *Journal of Machine Learning Research*.

Russell, Stuart J. & Norvig, Peter (2020). *Artificial Intelligence: A Modern Approach*. 4th Edition. Pearson.

He, Kaiming, et al. (2015). "*Deep Residual Learning for Image Recognition*." In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.

Rosasco, Lorenzo, et al. (2014). "*Learning and Generalization in Deep Networks*." *Foundations and Trends in Machine Learning*.

Goodfellow, Ian, Bengio, Yoshua, & Courville, Aaron (2016).

LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. "Deep learning." *Nature* 521.7553 (2015): 436-444.

He, Kaiming, et al. "Deep residual learning for image recognition." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.

Tschandl, P., et al. (2020). "The HAM10000 dataset: A large collection of multi-source dermatoscopic images of common pigmented skin lesions." *Scientific Data*, 7, 1-7.

Chollet, François. (2017).

Shorten, C., & Khoshgoftaar, T. M. (2019).



الجمهورية الجزائرية الديمقراطية الشعبية

وزارة التعليم العالي والبحث العلمي

جامعة عين تموشنت بلحاج بوشعيب

حاضنة الأعمال عين تموشنت



ملحق نموذج العمل التجاري

البطاقة التقنية للمشروع *Fiche technique du projet* ■

الاسم و اللقب Votreprénom et nom Your first and last Name	دامو محمد أسامة بلخضر اسماعيل
الاسم التجاري للمشروع Intitulé de votre projet Title of your Project	Derma Doctor
رقم الهاتف Votre numéro de téléphone Your phone number	0561-41-35-75 0553-69-19-67
البريد الإلكتروني Votreadresse e-mail Your email address	Masterinstrumentation2024@gmail.com
مقر مزاولة النشاط (الولاية- البلدية) Votrevilleou commune d'activité Your city or municipality of activity	ولاية عين تموشنت

طبيعة المشروع *Nature de projet* ■

المنتج ذو طابع خدماتي (تطبيق)

The product has a service nature (app)



المشكلة المراد حلها وتكون مدعمة بالبيانات (إحصائيات إن وجدت)

وفقاً لمنظمة الصحة العالمية (WHO)، يتم تسجيل حوالي 2 إلى 3 ملايين حالة جديدة سنوياً من سرطانات الجلد غير الميلانوما (Non-Melanoma Skin Cancer - NMSC) وحوالي 132,000 حالة جديدة من الميلانوما. يُعتبر الميلانوما مسؤولاً عن حوالي 75% من وفيات سرطان الجلد على الرغم من أنه أقل شيوعاً من الأنواع الأخرى. معدل الإصابة بالميلانوما يزداد بسرعة في كثير من الدول، خاصة في البلدان ذات البشرة الفاتحة مثل أستراليا ونيوزيلندا. لكن إذا تم اكتشافه وعلاجه مبكراً، فإن معدل البقاء على قيد الحياة لمدة 5 سنوات يمكن أن يصل إلى حوالي 99%.

1- القيمة المقترحة:

التعرف على الآفات الجلدية-

الكشف المبكر عن سرطان الجلد و بالتالي العلاج المبكر -

سهولة تحديد نوع السرطان-

ما طبيعة هذا الحل للمشكلة هل هي قيم نوعية أو كمية؟

بالحد من مخاطر الأمراض التي تصيب الجلد -

- جعل التطبيق سهل الاستعمال

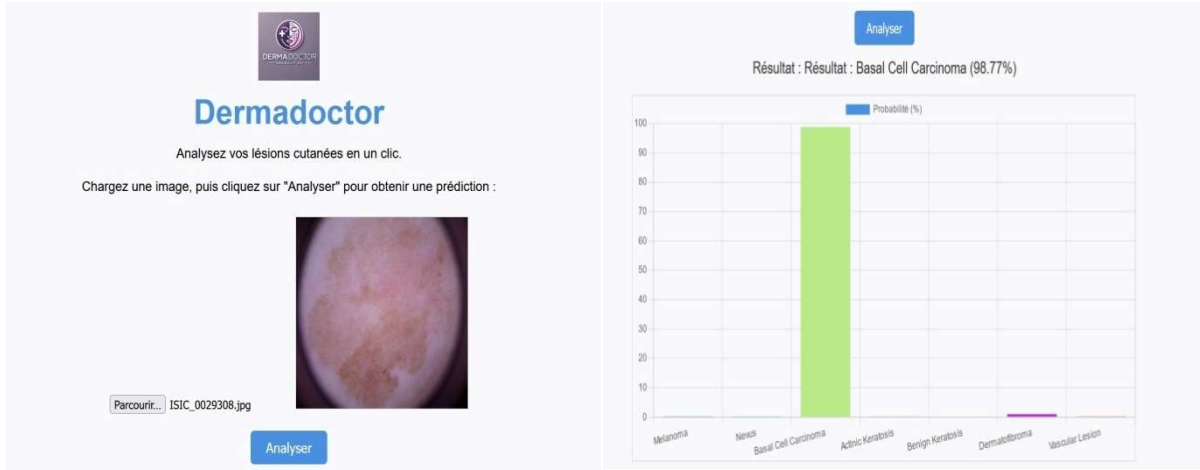
- قيمة مبتكرة و فكرة جديدة غير متوفرة بالجزائر حالياً.

1/1- القيمة التي نقدمها للعميل:

السماح للمستخدم بتحميل صورة لأفة جلدية-

يتم عرض النتيجة الأساسية (الفئة ذات الاحتمالية القصوى) على هيئة نص (على سبيل المثال: "تم - اكتشاف الورم الميلانيني بنسبة احتمال 85%").

يوضح الاحتمالات لكل فئة، مما يوفر تصوراً واضحاً للنتائج شريطي رسم بياني-



1/2- ما هي المشاريع الأخرى التي استهدفت نفس المشكلة والتي جرى تنفيذها؟

الخصائص في الجزائر. في الوقت الحالي ليس هناك أي مشروع أو تطبيق بنفس الفكرة أو حتى بنفس



2- شرائح العملاء :

الأطباء المختصون في الأمراض الجلدية

3 - العلاقات مع العملاء :

تكون الخدمة الذاتية من خلال التطبيق-

التحديثات والتحسينات-

تحسينات بناء على تعليقات المستخدمين-

القنوات-4:

1/4- الآليات والطرق لإعلام بمنتوجنا أو خدمتنا:

• موقع إلكتروني

تسويق عبر وسائل التواصل الاجتماعية.

2/4- قنوات التوزيع التي يفضلها العملاء:

في الوقت الحالي يقضي الناس الكثير من أوقاتهم على مواقع التواصل الاجتماعي و هذه فرصة جيدة للتعريف بتطبيقنا



1/5- الشركاء الرئيسيون الذين يمكن مساعدتنا:

- الأطباء المختصون في الأمراض الجلدية -
- مطوري الويب (développeurs web) -



6- الأنشطة الرئيسية:

- تطوير وصيانة التطبيق
- بناء وتحديث قاعدة بيانات أمراض الجلد
- إقامة شراكات مع الأطباء

- الموارد الرئيسية: 7

نقوم بتحديد فقط الموارد دون ذكر التكلفة.

1/ - الموارد المادية: 7

- قاعدة بيانات الأمراض الجلدية
- خوارزميات التعرف على الصور
- اتفاقيات الشراكة مع الأطباء
- فريق التطوير والخبرة

2/7- الموارد البشرية:

العدد	صنف المورد البشري
1	Web designer
1	Ingénieur en informatique
1	Dermatologue

structure Costs هيكل التكاليف 1/8 ▪

50000DA-100000DA	تكاليف التعريف بالمنتج أو المؤسسة <i>Frais d'établissement</i>	4.3
	تكاليف الحصول على العدادات (الماء- الكهرباء) <i>Frais d'ouverture de compteurs (eaux-gaz-....)</i>	4.3
	تكاليف (التكوين- برامج الاعلام الالى المختصة) <i>Logiciels, formations</i>	4.3
	<i>Dépôt marque, brevet, modèle</i>	4.3
	تكاليف براءة الاختراع و الحماية الصناعية و التجارية	4.3
	<i>Droits d'entrée</i>	4.3
	تكاليف الحصول على تكنولوجيا او ترخيص استعمالها	4.3
	<i>Achat fonds de commerce ou parts</i>	4.3
	شراء الأصول التجارية أو الأسهم	4.3
	<i>Droit au bail</i>	4.3
	الحق في الإيجار	4.3
	<i>Caution ou dépôt de garantie</i>	4.3
	وديعة أو وديعة تأمين	4.3
	<i>Frais de dossier</i>	4.3
	رسوم ايداع الملفات	4.3
	<i>Frais de notaire ou d'avocat</i>	4.3
	تكاليف الموثق-المحامي-.....	4.3
	<i>Enseigne et éléments de communication</i>	4.3
	تكاليف التعريف بالعلامة و تكاليف قنوات الاتصال	4.3
	<i>Achat immobilier</i>	4.3
	شراء العقارات	4.3
	<i>Travaux et aménagements</i>	4.3
	الأعمال والتحصينات الاماكن	4.3
200000DA	<i>Matériel</i>	4.3
	الالات- المركبات- الاجهزة	4.3
	<i>Matériel de bureau</i>	4.3
	تجهيزات المكتب	4.3
	<i>Stock de matières et produits</i>	4.3
	تكاليف التخزين	4.3
	<i>trésorerie de départ</i>	4.3
	التدفق النقدي (الصندوق) الذي تحتاجه في بداية المشروع	4.3

المجموع=250000DA

3- مصادر الإيرادات:

مميزات مميزة أو خيارات الاشتراك-

شراكات لتقاسم الأرباح-