

Apprentissage Artificiel Et Détection Des Tumeurs Cutanées A Partir D'IRM : Etude Empirique

[Artificial Learning And Skin Tumor Detection From MRI: An Empirical Study]

Mwangu Shanga Gabriel¹, Nembalemba Lowo Jean Patmos¹, Loso Kapita Percy¹, Mutombo Shanga Eddy²

¹Institut Supérieur d'Informatique, Programmation et Analyse, Section Sciences Informatiques, Kinshasa, RD Congo.

²Institut Supérieur de Techniques Appliquées de Gombe Matadi, Section Informatique, Mécanique, Construction, Mbanza-Ngungu, RD Congo.

Corresponding Author: Mwangu Shanga Gabriel



Abstract: This article discusses the artificial learning (machine learning) is revolutionizing early tumor detection, particularly in medical imaging. This empirical study demonstrates the effectiveness of a supervised learning model for predicting skin tumors from MRI images. With an accuracy of 98%, the developed model offers a powerful tool for early diagnosis, contributing to the reduction of melanoma-related mortality. The paper presents the theoretical foundations, methodology, experimental results, and clinical implications of this innovative approach.

Keywords: artificial learning, MRI, tumor, skin cancer, early detection, machine learning

Résumé : Cet article traite de l'apprentissage artificiel (machine learning) révolutionne la détection précoce des tumeurs, notamment dans l'imagerie médicale. Cette étude empirique démontre l'efficacité d'un modèle d'apprentissage supervisé pour la prédiction de tumeurs cutanées à partir d'images IRM. Avec une précision de 98 %, le modèle développé offre un outil performant pour le diagnostic précoce, contribuant à la réduction de la mortalité liée au mélanome. L'article présente les fondements théoriques, la méthodologie, les résultats expérimentaux et les implications cliniques de cette approche innovante.

Mots-clés : apprentissage artificiel, IRM, tumeur, cancer de la peau, détection précoce, machine learning

1. INTRODUCTION¹

L'apprentissage artificiel, branche dynamique et en pleine expansion de l'intelligence artificielle (IA), constitue aujourd'hui l'un des moteurs essentiels de l'innovation dans les technologies de l'information et de la communication. Cette discipline vise à doter les machines de la capacité d'apprendre à partir de données, de s'adapter à des environnements complexes et de prendre des décisions de plus en plus autonomes, sans intervention humaine directe.

Les applications de l'apprentissage artificiel se sont multipliées au cours des dernières décennies, transformant radicalement de nombreux secteurs. Dans la vie quotidienne, il permet aux smartphones de reconnaître les visages et les voix, aux assistants virtuels de comprendre le langage naturel, ou encore aux moteurs de recherche de proposer des résultats personnalisés en fonction des

¹ Corresponding Author : Mwangu Shanga Gabriel

préférences des utilisateurs. Dans l'industrie, il optimise la maintenance prédictive, la gestion des stocks et la logistique. En santé, il révolutionne le diagnostic médical, la découverte de nouveaux médicaments et la personnalisation des traitements.

Ce qui relevait autrefois de la science-fiction des machines capables de percevoir, d'apprendre et d'agir de manière intelligente est désormais une réalité tangible. Les progrès fulgurants de la puissance de calcul, la disponibilité de vastes ensembles de données (big data) et le développement d'algorithmes sophistiqués, tels que les réseaux de neurones profonds, ont permis à l'apprentissage artificiel de franchir des seuils de performance inédits.

Pourtant, derrière cette apparente magie se cachent des principes mathématiques et statistiques rigoureux. L'apprentissage artificiel repose sur la capacité des algorithmes à extraire des motifs pertinents à partir de données brutes, à généraliser à de nouveaux cas et à s'améliorer continuellement grâce à l'expérience. Cette faculté d'auto-amélioration, qui distingue l'apprentissage artificiel des systèmes informatiques traditionnels, ouvre la voie à des applications toujours plus complexes et à fort impact sociétal.

Dans le domaine médical, et plus particulièrement en imagerie, l'apprentissage artificiel s'impose comme un outil incontournable pour l'analyse automatisée de données massives et hétérogènes. Il permet d'augmenter la précision des diagnostics, de réduire les erreurs humaines et d'accélérer la prise de décision clinique. L'intégration de ces technologies dans la détection précoce des tumeurs, notamment à partir d'images d'IRM, représente un enjeu majeur pour la santé publique, en particulier face à l'augmentation de l'incidence des cancers de la peau.

Cet article s'inscrit dans cette dynamique et propose une étude empirique sur l'utilisation de l'apprentissage artificiel pour la détection automatisée des tumeurs cutanées à partir d'IRM. Nous présenterons les fondements théoriques de la discipline, la méthodologie adoptée, les résultats obtenus et les perspectives cliniques offertes par cette approche innovante.

Figure 1 : Simulation du cerveau humain par ordinateur



2. FONDEMENTS THEORIQUES ET HISTORIQUES

L'apprentissage artificiel, ou machine learning, constitue l'un des piliers de l'intelligence artificielle moderne. Son objectif principal est de permettre aux ordinateurs d'apprendre à partir de données, d'identifier des motifs complexes et de prendre des décisions adaptées à des situations nouvelles, sans qu'il soit nécessaire de programmer explicitement chaque règle ou comportement. Cette capacité d'adaptation et de généralisation distingue fondamentalement l'apprentissage artificiel des approches informatiques traditionnelles, basées sur des instructions déterministes.

2.1. LES GRANDES APPROCHES DE L'APPRENTISSAGE ARTIFICIEL

Deux grandes familles d'approches structurent le champ de l'apprentissage artificiel :

- **L'apprentissage supervisé** : Il s'agit de la méthode la plus répandue, dans laquelle le modèle est entraîné à partir d'un ensemble de données étiquetées, c'est-à-dire pour lesquelles la réponse attendue est connue. L'algorithme apprend à associer des entrées (par exemple, des images médicales) à des sorties (diagnostic de tumeur ou non), en ajustant ses paramètres pour minimiser

l'erreur de prédiction. Les tâches typiques incluent la classification (attribution d'une catégorie) et la régression (prédiction d'une valeur continue).

- **L'apprentissage non supervisé** : Ici, les données d'entraînement ne comportent pas d'étiquettes. L'objectif est alors de découvrir des structures cachées ou des regroupements naturels dans les données, comme le clustering (regroupement de patients selon des profils similaires) ou la réduction de dimensionnalité (extraction des caractéristiques les plus pertinentes).

D'autres paradigmes existent, tels que l'apprentissage semi-supervisé (mélange de données étiquetées et non étiquetées), l'apprentissage par renforcement (apprentissage par essai-erreur guidé par des récompenses) et l'apprentissage par transfert (réutilisation de connaissances acquises sur une tâche pour en aborder une nouvelle).

2.2. JALONS HISTORIQUES

L'histoire de l'apprentissage artificiel est jalonnée de contributions majeures, qui ont progressivement permis de passer de concepts théoriques à des applications concrètes et performantes.

- **Alan Turing (années 1940-1950)** : Considéré comme l'un des pères fondateurs de l'intelligence artificielle, Turing a posé les bases de la réflexion sur les machines capables d'apprendre, notamment à travers le concept de « machine universelle » et le célèbre « test de Turing ».
- **Réseaux de neurones artificiels (années 1940-1960)** : Warren McCulloch et Walter Pitts (1943) proposent le premier modèle mathématique du neurone formel, inspiré du fonctionnement biologique. Frank Rosenblatt développe ensuite le perceptron (1957), premier réseau de neurones capable d'apprentissage supervisé simple.
- **Machine Learning et algorithmes statistiques (années 1960-1990)** : L'expression « machine learning » est popularisée par Arthur Samuel (1959), qui conçoit un programme de jeu de dames s'améliorant par l'expérience. Les décennies suivantes voient l'émergence d'algorithmes fondamentaux : k-plus proches voisins, arbres de décision, régression logistique, machines à vecteurs de support (SVM), etc.
- **Réseaux de neurones profonds et deep learning (années 2000-2010)** : Grâce à l'augmentation de la puissance de calcul et à la disponibilité de grandes bases de données, les réseaux de neurones multicouches (deep neural networks) connaissent un essor spectaculaire. Des architectures comme les réseaux de neurones convolutifs (CNN) pour l'image ou les réseaux récurrents pour le texte permettent d'atteindre des performances inédites dans de nombreux domaines, dont la santé.

2.3. FONDEMENTS MATHÉMATIQUES ET STATISTIQUES

L'apprentissage artificiel repose sur des outils mathématiques issus des statistiques, de l'optimisation et de l'algèbre linéaire. Les modèles apprennent à partir de données en ajustant leurs paramètres pour minimiser une fonction de coût (ou fonction de perte), qui mesure l'écart entre la prédiction et la réalité. Les techniques d'optimisation, comme la descente de gradient, sont au cœur de l'entraînement des modèles modernes.

La capacité à généraliser, c'est-à-dire à bien prédire sur de nouvelles données jamais vues, est un enjeu central. Elle dépend de la qualité des données, du choix du modèle, de la régularisation et de la gestion du surapprentissage (overfitting).

2.4. VERS DES APPLICATIONS MÉDICALES

Aujourd'hui, l'apprentissage artificiel s'impose comme un outil incontournable pour l'analyse de données médicales massives et complexes. Il permet d'automatiser la détection d'anomalies sur des images (radiographies, IRM), d'anticiper l'évolution de maladies ou de personnaliser les traitements. Les réseaux de neurones profonds, en particulier, ont démontré leur supériorité pour la reconnaissance de motifs subtils dans les images médicales, ouvrant la voie à une médecine plus précise et prédictive.

3. PROCESSUS ET TYPES D'APPRENTISSAGE

L'apprentissage artificiel repose sur un processus structuré qui permet à un système informatique d'extraire des connaissances à partir de données et d'appliquer ces connaissances à de nouveaux cas. Ce processus se divise généralement en deux grandes phases : la phase d'apprentissage (ou d'entraînement) et la phase de réalisation de la tâche (ou d'inférence).

3.1. PHASE D'APPRENTISSAGE (ENTRAÎNEMENT)

La phase d'apprentissage consiste à exposer un algorithme à un ensemble de données d'entraînement, souvent appelé « training set ». Ces données sont composées d'exemples représentatifs du problème à résoudre, chaque exemple étant constitué d'entrées (features) et, dans le cas de l'apprentissage supervisé, de sorties attendues (labels). L'algorithme ajuste alors ses paramètres internes afin de minimiser l'écart entre ses prédictions et les résultats attendus, selon une fonction de coût ou de perte.

Par exemple, dans le cas de la détection de tumeurs sur des images IRM, le modèle est entraîné à partir d'un grand nombre d'images annotées, où chaque image est associée à la présence ou l'absence d'une tumeur. L'algorithme apprend à reconnaître les motifs caractéristiques des tumeurs en ajustant ses poids internes.

L'efficacité de cette phase dépend de la qualité et de la quantité des données, du choix de l'algorithme, de la sélection des hyperparamètres et de la gestion des biais et du surapprentissage (overfitting).

3.2. PHASE DE REALISATION DE LA TACHE (INFERENCE)

Une fois le modèle entraîné, il entre dans la phase de réalisation de la tâche, aussi appelée phase d'inférence ou de prédiction. À ce stade, le modèle est confronté à de nouvelles données, jamais vues lors de l'entraînement, et doit appliquer les connaissances acquises pour effectuer des prédictions ou des classifications.

Dans le contexte médical, cela signifie que le modèle peut analyser de nouvelles images IRM et indiquer la probabilité de présence d'une tumeur, aidant ainsi le clinicien dans sa prise de décision. La performance du modèle est alors évaluée à l'aide de métriques telles que la précision, le rappel, la spécificité ou l'aire sous la courbe ROC (Receiver Operating Characteristic).

3.3. TYPES D'APPRENTISSAGE

L'apprentissage artificiel se décline en plusieurs types, selon la nature des données et des tâches à accomplir :

- **Apprentissage supervisé** : L'algorithme apprend à partir de données étiquetées. Il s'agit du cadre le plus courant pour la classification (ex : diagnostic de maladies) et la régression (ex : prédiction de la progression d'une maladie). Les réseaux de neurones, les forêts aléatoires et les machines à vecteurs de support sont des exemples d'algorithmes utilisés.
- **Apprentissage non supervisé** : Ici, les données ne comportent pas d'étiquettes. L'objectif est de découvrir des structures cachées, comme des groupes ou des motifs récurrents. Les techniques de clustering (ex : k-means) et de réduction de dimensionnalité (ex : PCA) sont courantes. En santé, cela peut servir à segmenter des populations de patients selon leurs profils de risque.
- **Apprentissage semi-supervisé** : Ce type combine un petit nombre de données étiquetées et un grand nombre de données non étiquetées, permettant d'améliorer la performance lorsque l'annotation des données est coûteuse ou difficile.
- **Apprentissage par renforcement** : L'algorithme apprend par essais et erreurs, recevant des récompenses ou des pénalités selon la qualité de ses actions. Ce paradigme est particulièrement utilisé pour l'optimisation de stratégies ou la robotique médicale.
- **Apprentissage par transfert** : Il s'agit de réutiliser un modèle préalablement entraîné sur une tâche similaire pour accélérer l'apprentissage sur une nouvelle tâche, ce qui est particulièrement utile lorsque les données sont rares.

3.4. IMPORTANCE DU PRETRAITEMENT ET DE LA VALIDATION

Le succès du processus d'apprentissage dépend également du prétraitement des données (nettoyage, normalisation, augmentation des données) et de la validation croisée, qui permet d'évaluer la capacité du modèle à généraliser sur des données inédites et d'éviter le surapprentissage.

Figure 2 : Schéma du processus d'apprentissage machine

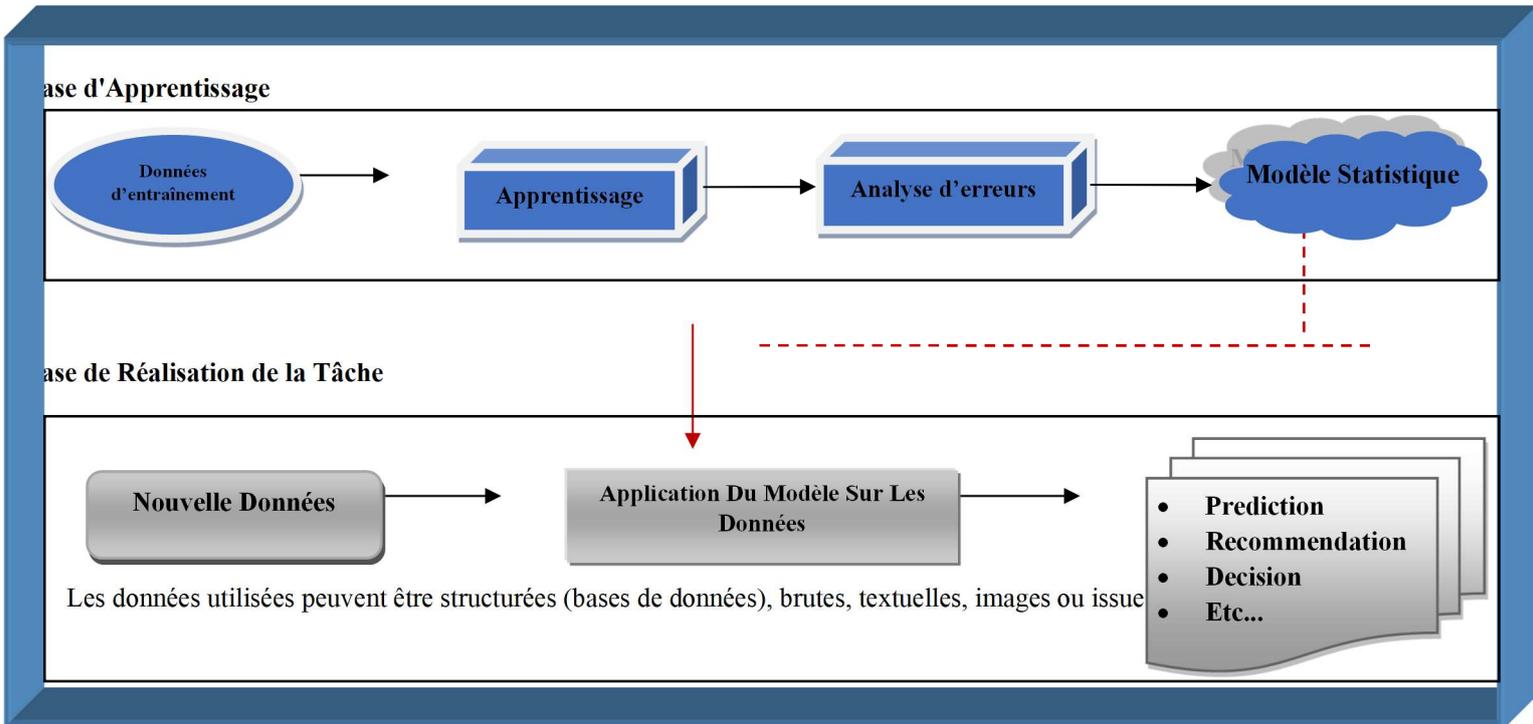


Figure 3 : Exemple de détection d'un objet (poisson) par machine vision.



Figure 4 : Application de l'apprentissage artificiel à l'Internet des objets (IoT).



Les tâches typiques incluent la classification, la régression, la recommandation et le clustering.

4. Réseaux de neurones à convolution (CNN)

Les réseaux de neurones à convolution (Convolutional Neural Networks, CNN) représentent une avancée majeure dans le domaine de l'apprentissage profond, en particulier pour le traitement et la classification d'images. Leur architecture, inspirée du fonctionnement du cortex visuel des mammifères, est spécialement conçue pour extraire automatiquement des caractéristiques pertinentes à partir de données visuelles, sans nécessiter d'ingénierie manuelle des variables.

4.1. Principe de fonctionnement

Un CNN est composé de plusieurs types de couches, chacune jouant un rôle spécifique dans l'extraction et la transformation des informations contenues dans une image :

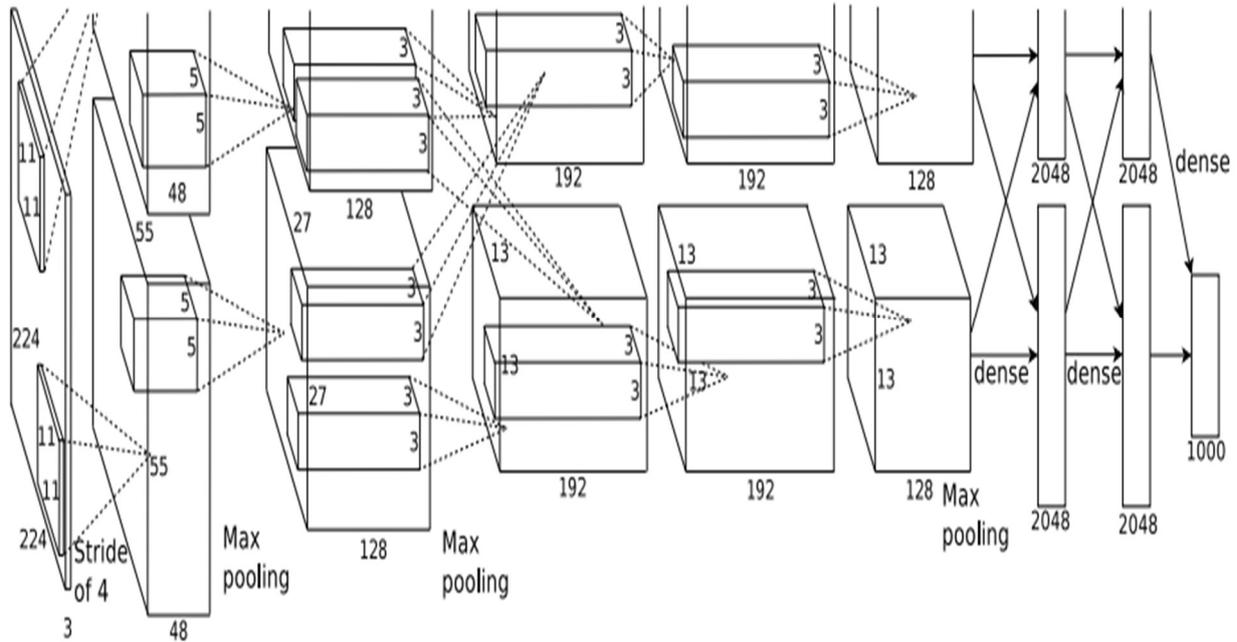
- **Couches de convolution** : Ces couches appliquent des filtres (ou noyaux) sur l'image d'entrée afin de détecter des motifs locaux, tels que des bords, des textures ou des formes. Chaque filtre parcourt l'image et produit une carte d'activation qui met en évidence la présence du motif recherché à différents endroits de l'image. L'apprentissage des poids des filtres se fait automatiquement lors de l'entraînement du réseau.
- **Couches de pooling (regroupement)** : Ces couches réduisent la dimensionnalité des cartes d'activation en conservant l'information la plus importante, généralement via un maximum (max pooling) ou une moyenne (average pooling). Cette opération permet de rendre le modèle plus robuste aux variations de position et de taille des objets dans l'image, tout en diminuant le nombre de paramètres et le risque de surapprentissage.
- **Couches d'activation** : Après chaque opération de convolution, une fonction d'activation non linéaire (comme la fonction ReLU : Rectified Linear Unit) est appliquée pour introduire de la non-linéarité dans le modèle, ce qui permet de modéliser des relations complexes entre les pixels.
- **Couches entièrement connectées (fully connected)** : En fin de réseau, ces couches reçoivent les caractéristiques extraites par les couches précédentes et réalisent la classification finale, en attribuant à chaque image une probabilité d'appartenance à chaque classe possible (par exemple, présence ou absence de tumeur).

4.2. Architectures emblématiques

Plusieurs architectures de CNN ont marqué l'histoire de l'apprentissage profond :

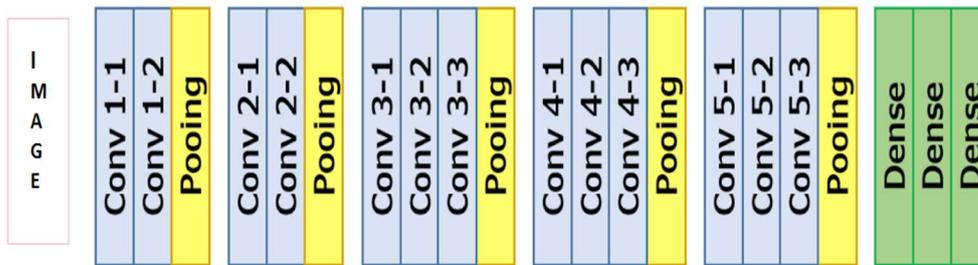
- **AlexNet** : Premier réseau à avoir remporté le concours ImageNet en 2012, AlexNet a démontré la supériorité des CNN pour la classification d'images à grande échelle (Krizhevsky, Sutskever & Hinton, 2012).

Figure 5 : Architecture du réseau AlexNet, source : « ImageNet Classification with Deep Convolutional Neural Networks » Alex Krizhevsky, Ilya Sutskever and Geoffrey E. Hinton.



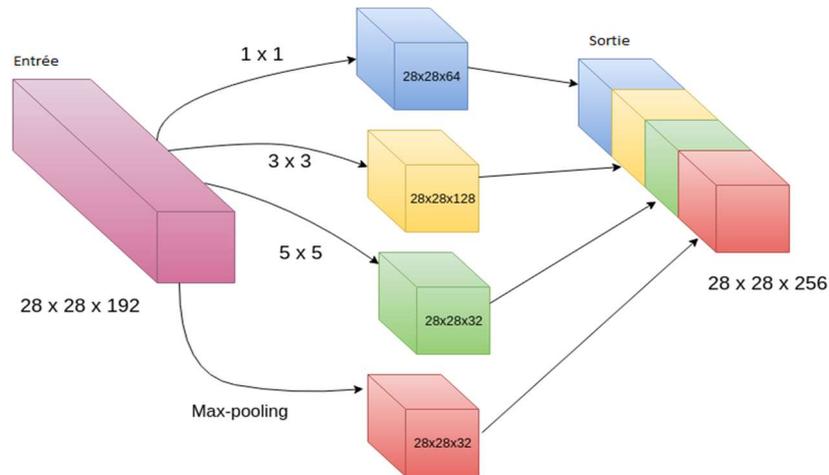
- **VGGNet :** Proposée par Simonyan et Zisserman (2014), cette architecture se distingue par sa profondeur et l'utilisation systématique de petits filtres 3x3, améliorant la capacité de représentation du réseau.

Figure 6 : Architecture du réseau VGG 16



- **GoogLeNet (Inception) :** Cette architecture introduit des modules « inception » qui permettent de capturer des motifs à différentes échelles, tout en optimisant le nombre de paramètres (Szegedy et al., 2015).

Figure 7 : Exemple d'une couche de lancement, avec 64 convolutions 1x1, 128 convolutions 3x3, 32 convolution 5x5, et 32 max-pooling



4.3. Application à la détection de tumeurs

Dans le contexte médical, les CNN sont utilisés pour analyser des images d'IRM, de radiographies ou de scanners afin de détecter automatiquement la présence de tumeurs ou d'autres anomalies. L'entraînement du réseau se fait à partir d'un grand nombre d'images annotées par des experts, et le modèle apprend à distinguer les caractéristiques subtiles qui différencient les tissus sains des tissus pathologiques.

5. IRM et détection des tumeurs

L'IRM est un examen d'imagerie non invasif, essentiel pour détecter des anomalies internes, dont les tumeurs. Elle permet d'obtenir des images détaillées, facilitant la détection précoce des cancers de la peau, notamment le mélanome.

6. Étude empirique : détection de tumeurs à partir d'IRM

6.1. Problématique

Le cancer de la peau, en particulier le mélanome, est en forte augmentation. Sa détection précoce est cruciale pour le pronostic. Les mélanomes achromiques, sans couleur, sont particulièrement difficiles à détecter.

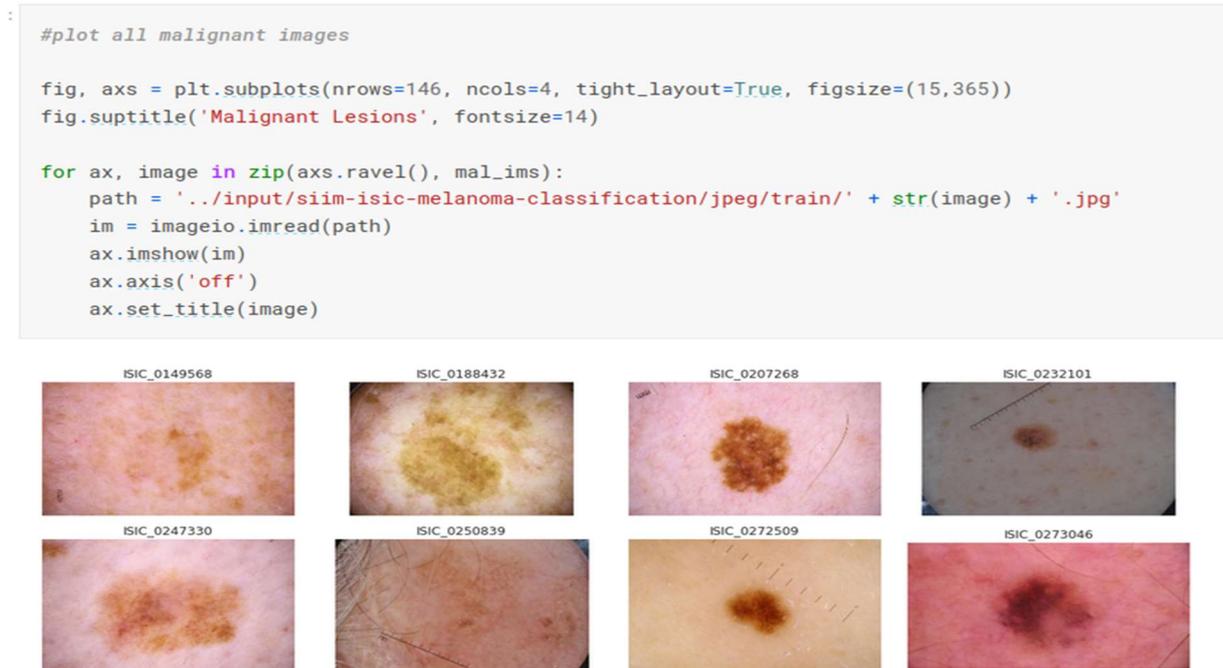
Figure 8 : Mélanome achromique (boule couleur peau sur la paume ou la plante du pied).



6.2. Méthodologie

Un modèle CNN a été entraîné sur un jeu de données d'IRM annotées. L'architecture comprend des couches de convolution, pooling, activation (ReLU) et une couche entièrement connectée pour la classification.

Figure 9 : Entraînement du model sur les données (images)



6.3. Résultats

Le modèle atteint une précision de 98 % sur le jeu de test, démontrant sa capacité à détecter les tumeurs cutanées, y compris les cas atypiques.

Figure 10 : Précision du modèle sur de nouveaux cas (98%).



7. Discussion

L'intégration de l'apprentissage artificiel dans l'analyse des IRM permet de réduire le temps d'interprétation, d'améliorer la détection des tumeurs précoces et d'offrir un outil d'aide à la décision robuste. Les défis restent l'explicabilité des modèles et leur intégration dans les workflows cliniques.

8. Implications cliniques et perspectives

L'adoption de l'apprentissage artificiel pour l'analyse des IRM ouvre la voie à une médecine prédictive et préventive, standardise l'interprétation des images et facilite la surveillance à distance des patients à risque.

9. Conclusion

Dans cet article, nous avons mené une étude empirique qui valide l'efficacité et la fiabilité de l'intelligence artificielle pour la détection des tumeurs cutanées à partir de l'IRM. Le modèle que nous avons développé affiche une précision exceptionnelle de 98%, assurant ainsi des performances robustes, y compris pour les cas inédits. Bien que le mélanome ne représente qu'1% des cancers de la peau, il demeure le plus mortel et la principale cause de décès associée à ces cancers. Il touche particulièrement les jeunes adultes et présente une incidence alarmante à l'échelle mondiale, notamment en Australie et en Nouvelle-Zélande. Dans ce contexte, notre modèle s'impose comme une avancée significative pour le diagnostic précoce et la prise en charge du mélanome.

REMERCIEMENTS

Nous tenons à exprimer notre profonde gratitude à toutes celles et à tous ceux qui, de près ou de loin, ont apporté leur précieuse contribution à la rédaction de cet article.

REFERENCES

- [1] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- [2] Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition.
- [3] American Cancer Society. (2023). *Cancer Facts & Figures 2023*.
- [4] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- [5] Topol, E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44-56.
- [6] Litjens, G., et al. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
- [7] Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.
- [8] Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 3(3), 210-229.
- [9] Turing, A. M. (1950). Computing machinery and intelligence. *Mind*, 59(236), 433-460.
- [10] Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.