

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université de Mohamed El-Bachir El-Ibrahimi - BBA
Faculté des Mathématiques et Informatiques



MÉMOIRE

Présenté en vue de l'obtention du diplôme

Master en Informatique

Spécialité : Ingénierie de l'Informatique Décisionnelle

Thème

Prédiction de l'autisme à partir de données médicales en utilisant l'apprentissage profond

Présenté par :

- SOUADIA Radhia
- MOKHTAR AHDOUGA Chaima

Soutenu le : 11/6/2025, devant la commission d'examen suivante :

Dr. MAACH Salah	Enseignant à l'université de BBA	Président
Dr. REGOUID Meryem	Enseignant à l'université de BBA	Examineur
Pr. ATTIA Abdelouaheb	Enseignant à l'université de BBA	Encadrant

Promotion 2024 / 2025

**“L’autisme n’est pas un handicap,
c’est une façon différente de
penser.”**

Selon - Dr. Temple Grandin - “Auteur, inventeur et expert
américain en comportement animal.”

Résumé

Cette étude vise à explorer le potentiel de l'utilisation des techniques d'IA, en particulier l'apprentissage profond, pour diagnostiquer les troubles du spectre autistique (TSA) sur la base d'images faciales. L'autisme est un trouble neurologique complexe difficile à diagnostiquer avec précision, ce qui fait des outils d'IA une solution prometteuse pour accélérer et améliorer le processus de diagnostic. Dans ce travail, des réseaux de neurones convolutifs (CNN) sont adoptés pour extraire des caractéristiques visuelles distinctives des images de visage, en utilisant plusieurs modèles bien connus tels que "ResNet50V2", "InceptionV3", "DenseNet121" et "VGG16". Après le prétraitement des données, ces modèles ont été formés et leurs performances évaluées à l'aide de mesures précises telles que la précision de la classification, la matrice de confusion et les courbes ROC. Les résultats ont montré que le modèle proposé était capable de distinguer les enfants autistes et non autistes avec un degré élevé de précision, améliorant ainsi le potentiel d'utilisation de ces techniques comme outil de soutien dans le domaine médical, en particulier dans les premières étapes de détection.

Mots-clés :

Intelligence Artificielle (IA)

Apprentissage profond

Troubles du spectre autistique (TSA)

Réseaux de neurones convolutifs (CNN)

Abstract

This study aims to explore the potential of using AI techniques, particularly deep learning, to diagnose autism spectrum disorders (ASD) based on facial images. Autism is a complex neurological disorder that is difficult to diagnose accurately, making AI tools a promising solution to accelerate and improve the diagnostic process. In this work, convolutional neural networks (CNNs) are adopted to extract distinctive visual features from facial images, using several well-known models such as "ResNet50V2", "InceptionV3", "DenseNet121" and "VGG16". After data preprocessing, these models were trained and their performance evaluated using specific metrics such as classification accuracy, confusion matrix, and ROC curves. The results showed that the proposed model was able to distinguish between autistic and non-autistic children with a high degree of accuracy, thus improving the potential for using these techniques as a support tool in the medical field, especially in the early stages of detection.

Keywords :

Artificial Intelligence (AI)

Deep Learning

Autism Spectrum Disorder (ASD)

Convolutional Neural Networks (CNN)

ملخص

تهدف هذه الدراسة إلى استكشاف إمكانيات استخدام تقنيات الذكاء الاصطناعي، وخاصة التعلم العميق، لتشخيص اضطرابات طيف التوحد بناءً على صور الوجه. يُعد التوحد اضطرابًا عصبيًا معقدًا يصعب تشخيصه بدقة، مما يجعل أدوات الذكاء الاصطناعي حلاً واعدًا لتسريع عملية التشخيص وتحسينها. في هذا العمل، تم اعتماد الشبكات العصبية التلافيفية لاستخراج السمات "ResNet50V2" البصرية المميزة من صور الوجه، باستخدام العديد من النماذج المعروفة مثل بعد معالجة البيانات مسبقًا، تم تدريب "VGG16" و "DenseNet121" و "InceptionV3" و هذه النماذج وتقييم أدائها باستخدام مقاييس دقيقة مثل دقة التصنيف ومصفوفة الارتباك ومنحنيات أظهرت النتائج أن النموذج المقترح قادر على التمييز بين الأطفال المصابين بالتوحد ROC. وغير المصابين به بدقة عالية، مما يعزز إمكانية استخدام هذه التقنيات كأداة دعم في المجال الطبي، وخاصة في المراحل المبكرة من الكشف

الكلمات المفتاحية

الذكاء الاصطناعي

التعلم العميق

اضطراب طيف التوحد

الشبكات العصبية التلافيفية

Remerciements

Nous remercions avant tout **ALLAH**, le Tout-Puissant, de nous avoir accordé la force, la patience et la persévérance nécessaires pour mener à bien ce travail.

Nous exprimons notre profonde gratitude à notre encadrant, **Pr. ATTIA Abdelouaheb**, pour son soutien et la qualité de son encadrement. Ses conseils et son soutien ont été essentiels à la réussite de cette thèse. Nous lui adressons nos sincères remerciements et notre plus haute reconnaissance.

Nos remerciements s'adressent également aux membres du jury qui nous font l'honneur d'évaluer ce travail, et dont les remarques pertinentes ne manqueront pas d'enrichir notre réflexion.

Nous exprimons aussi notre reconnaissance à toutes les personnes qui, de près ou de loin, ont contribué à la réalisation de ce projet. Leur soutien, leurs encouragements et leurs apports ont été d'un grand secours tout au long de notre parcours.

Nos remerciements vont également à l'ensemble des enseignants et du personnel du département d'informatique pour la qualité de l'encadrement, l'enseignement dispensé, ainsi que leur engagement envers les étudiants.

Enfin, nous tenons à remercier tout le personnel de l'Université Mohamed Bachir El Ibrahimy pour ses efforts visant à assurer un environnement propice à l'apprentissage et au développement académique.

Merci à toutes et à tous.

Dédicace

Je dédie ce travail, avant tout, à Dieu tout-puissant, qui m'a donné la force, la patience et le succès pour terminer ce chemin.

À ma mère, mon premier soutien dans cette vie.

À l'âme pure de mon père qui est décédé mais qui m'accompagne toujours à chaque pas que je fais.

À ma chère sœur et mes chères frères, pour leur soutien continu et leurs sincères encouragements.

À mes vrais amis, qui ont toujours été là pour moi à tout moment.

À tous ceux qui ont cru en moi, de près ou de loin, et qui ont eu un impact sur cette réussite.

À peuple de Gaza.

À vous tous.

★ *Chaima* ★

Dédicace

Du plus profond de notre cœur, nous dédions ce modeste travail à toutes les personnes qui nous ont soutenus, aidés et conseillés tout au long de notre vie. Nous exprimons notre gratitude et notre respect à :

Nos chères mères, pour tout leur amour et leur dévouement,

Nos pères, qui nous ont donné de magnifiques exemples de travail et de persévérance,

Nos frères et sœurs bien-aimés, pour leur soutien moral et leurs sacrifices durant toute notre formation,

Tous nos collègues de l'université,

Enfin, à toutes les personnes qui ont, de près ou de loin, contribué à la réalisation de ce travail.

★ *Radhia* ★

Table des matières

Abstract	ii
Liste des figures	xiii
Liste des tableaux	xiv
Abréviations	xv
Introduction Générale	1
1 Généralités sur l’Autism	5
1.1 Introduction	5
1.2 L’Autism : Définition et Enjeux	5
1.2.1 Définition des maladies chroniques	6
1.2.2 Prévalence et Incidence	10
1.2.3 Facteurs de risque	12
1.3 L’utilisation des données médicales en santé	14
1.3.1 Types de données médicales	15
1.3.2 Sources des Données Médicales	17
1.4 Conclusion	18
2 Techniques d’intelligence artificielle pour détecter l’autisme	19
2.1 Introduction	19

2.2	Introduction à l'intelligence artificielle	20
2.2.1	Définition de l'intelligence artificielle	20
2.2.2	Evolution historique	21
2.2.3	Types d'intelligence artificielle	22
2.2.4	Applications de l'intelligence artificielle dans divers domaines . .	22
2.2.5	La relation entre le big data et l'intelligence artificielle	23
2.3	Bases de l'apprentissage automatique	23
2.3.1	Définition de l'apprentissage automatique	24
2.3.2	Types d'apprentissage automatique	24
2.3.3	Algorithmes de base pour l'apprentissage automatique	27
2.3.4	Limites de l'apprentissage automatique	29
2.4	Apprentissage profond	30
2.4.1	Définition de l'apprentissage profond	31
2.4.2	Histoire de l'apprentissage profond	31
2.4.3	Objectif d'apprentissage profond	32
2.4.4	Les réseaux de neurones	32
2.4.5	Les techniques d'apprentissage profond	33
2.4.6	La différence entre l'apprentissage automatique et l'apprentissage profond	36
2.5	la détection de l'autisme	37
2.5.1	L'importance de détecter l'autisme	37
2.5.2	Comment détecter l'autisme	37
2.6	le futur de l'apprentissage profond dans le diagnostic médical	38
2.7	État de l'art	40
2.7.1	Méthodes traditionnelles	40
2.7.2	méthodes modernes	41
2.8	Conclusion	43

3	Conception	44
3.1	Introduction	44
3.2	Architecture générale du système proposé	44
3.3	Apprentissage par transfert	45
3.3.1	Apprentissage par transfert versus ajustement fin (Fine-Tuning)	46
3.3.2	Approches de l'apprentissage par transfert	46
3.4	Architecture du CNN	47
3.4.1	Couche de Convolution	47
3.4.2	Mise en commun maximale :MaxPooling	48
3.4.3	Entièrement connecté :Fully Connected	48
3.5	Sous-modèles CNN	48
3.5.1	ResNet50V2	49
3.5.2	InceptionV3	49
3.5.3	VGG16	50
3.5.4	DenseNet121	50
3.6	Conclusion	50
4	Implémentation et Évaluation	52
4.1	Introduction	52
4.2	Cadre de développement	52
4.2.1	Le langage de programmation utilisé(Python)	53
4.2.2	Plateforme (Google Colab)	54
4.3	Approche de classification d'images faciales pour le TSA	55
4.3.1	Présentation des bases de données utilisées	55
4.3.2	Prétraitement des données	58
4.3.3	Extraction des caractéristiques	59
4.3.4	Choix du modèle de classification	60
4.3.5	Prise de décision et prédiction	60

4.4	Métriques d'évaluation du modèle	61
4.4.1	Analyse de la courbe d'apprentissage précision et perte (Accuracy and Loss)	61
4.4.2	Matrice de confusion	63
4.4.3	Courbe de ROC(Receiver Operating Characteristic)	65
4.4.4	Analyse des courbes ROC	65
4.4.5	Indicateurs de performance de classification	66
4.4.6	Rapport de classification	67
4.5	Études expérimentales sur les performances des modèles CNN	68
4.6	Conclusion	70
	Conclusion Générale	71
	Bibliographie	73

Table des figures

1.1	évolution des connaissances sur l'autisme.	9
2.1	Les domaines de l'IA.	20
2.2	Apprentissage automatique.	24
2.3	Apprentissage Supervisé.	25
2.4	Apprentissage non Supervisé.	26
2.5	apprentissage semi-supervisé.	26
2.6	Apprentissage par Renforcement.	27
2.7	Exemple d'arbre de décision.	28
2.8	Réseaux à vecteurs de support.	29
2.9	Un schéma du fonctionnement d'un réseau neuronal.	33
2.10	Réseaux RNN.	34
2.11	Réseaux CNN.	35
3.1	Flux de travail pour la détection des troubles du spectre autistique à l'aide de l'apprentissage profond.	45
3.2	Schéma fonctionnel de l'architecture de base du réseau neuronal convolutif (CNN).	49
4.1	Logo Python.	53
4.2	Logo colab.	55
4.3	Courbes d'apprentissage (Précision et Perte) pour les deux jeux de données.	63

4.4	Matrice de confusion pour les deux ensembles de données utilisés. . . .	64
4.5	Courbe ROC – Base Autism Image Data	66
4.6	Courbe ROC – Base YTUIA_2D	66

Liste des tableaux

1.1	Prévalence de l'autisme dans les différentes régions du monde de 2012 à 2021	12
2.1	Comparaison entre l'apprentissage automatique et l'apprentissage profond	36
2.2	Résultats de la prédiction des troubles du spectre autistique à l'aide de techniques d'apprentissage automatique	41
2.3	Comparaison des performances des modèles pour le diagnostic du TSA	42
2.4	Résultat de performance du modèle ResNet50	43
4.1	Comparaison des prétraitements des deux bases de données	59
4.2	Comparaison des modèles utilisés pour l'extraction de caractéristiques .	60
4.3	Rapport de classification du BDD 1.	68
4.4	Rapport de classification du BDD 2	68
4.5	Résultats expérimentaux des tests de modèles CNN sur deux bases de données	69

Abréviations

- ASD** ou TSA (Autism Spectrum Disorder) : Trouble du Spectre Autistique .
- AUC** (Area Under the Curve) : Aire sous la Courbe ROC .
- BDD** : Base de données .
- CNN** (Convolutional Neural Network) : Réseau de Neurones Convolutif .
- DSM-V** (Diagnostic and Statistical Manual of Mental Disorders) : Manuel diagnostique et statistique des troubles mentaux .
- EEG** (Électroencéphalogramme) : Électroencéphalogramme .
- FN** (False Negatives) : Faux Négatifs .
- FP** (False Positives) : Faux Positifs .
- F1-Score** : Score F1 .
- GAN** (Generative Adversarial Network) : Réseaux Antagonistes Génératifs .
- IA** (Intelligence Artificielle) : Intelligence Artificielle .
- IoT** (Internet of Things) : Internet des Objets.
- ML** (Machine Learning) : Apprentissage Automatique .
- MRI** (Magnetic Resonance Imaging) : Imagerie par Résonance Magnétique .
- PET** (Positron Emission Tomography) : Tomographie par Émission de Positons .
- RNN** (Recurrent Neural Network) : Réseau Neuronal Récurrent .
- ROC** (Receiver Operating Characteristic) : Courbe ROC .
- SVM** (Support Vector Machine) : Machines à Vecteurs de Support .

-**TN** (True Negatives) : Vrais Négatifs .

-**TP** (True Positives) : Vrais Positifs .

Introduction Générale

Le trouble du spectre autistique (TSA) est l'un des troubles neurodéveloppementaux les plus complexes, caractérisé par son impact sur la communication, le comportement et l'interaction sociale. Avec sa prévalence croissante à l'échelle mondiale, il existe un besoin urgent d'outils de diagnostic précis et efficaces pour une détection précoce.

Ces dernières années, les techniques d'intelligence artificielle, notamment l'apprentissage automatique et l'apprentissage profond, se sont avérées efficaces pour analyser les données médicales et extraire des modèles cachés qui peuvent être difficiles à détecter à l'aide des méthodes traditionnelles. Ce travail se concentre sur l'application de réseaux de neurones convolutifs (CNN) aux images faciales, dans le but de prédire la présence d'autisme à travers des caractéristiques visuelles distinctives.

Ce mémoire commence par un aperçu du concept d'autisme et de l'importance de l'analyse des données médicales, puis passe en revue diverses techniques d'intelligence artificielle utilisées dans le domaine de la santé. Ensuite, nous présentons la contribution proposée basée sur l'utilisation de modèles CNN pré-entraînés, suivie d'une section d'application qui comprend une explication de l'environnement de travail, la préparation des données, les résultats expérimentaux et l'évaluation des performances.

Problématique & Motivations

Malgré les progrès médicaux, l'autisme, un trouble neurologique complexe qui affecte le développement précoce, reste difficile à diagnostiquer. Ce diagnostic tardif peut avoir un impact significatif sur le développement de l'enfant. Avec l'essor de l'apprentissage profond dans le domaine médical, une opportunité est apparue d'améliorer la détection précoce et automatisée de l'autisme à partir de données médicales, notamment d'images.

Ce problème nous motive à utiliser des techniques d'apprentissage profond pour proposer une approche fiable et efficace pour détecter l'autisme.

Objectifs & Contributions

L'objectif principal de ce travail est de développer un modèle basé sur l'apprentissage profond pour détecter l'autisme à partir de données d'images médicales. Nos principales contributions sont les suivantes :

- Une étude comparative des méthodes d'apprentissage profond appliquées à la détection de l'autisme ;

- Prétraitement et annotation d'un ensemble de données d'images d'enfants avec et sans autisme ;

- Mettre en œuvre un modèle CNN haute performance pour la classification d'images ;

- Évaluation expérimentale rigoureuse des performances du modèle.

Organisation du mémoire

Ce mémoire est structuré en quatre chapitres principaux, chacun contribuant à la compréhension progressive du thème de la détection de l'autisme à l'aide de l'intelli-

gence artificielle , et c'est comme suit :

-Chapitre 1 : Généralités sur l'autisme

Ce chapitre fournit le cadre conceptuel et médical du travail de recherche. Il commence par une présentation des troubles du spectre autistique (TSA), y compris les définitions cliniques, la prévalence mondiale et les principaux facteurs de risque identifiés. Comme il présente également les différents types de données médicales utilisées dans le diagnostic des troubles du spectre autistique, ainsi que leurs sources.

-Chapitre 2 : Techniques d'intelligence artificielle pour détecter l'autisme

Ce chapitre passe en revue les concepts de base associés à l'intelligence artificielle et à ses développements, en mettant l'accent sur ses applications dans le domaine médical, notamment dans l'analyse des big data. Il aborde également les fondamentaux de l'apprentissage automatique et de l'apprentissage profond, soulignant le rôle de ces technologies dans la détection précoce de l'autisme et présentant les perspectives de leur utilisation future dans le diagnostic médical.

De plus, cette section comprend une rubrique principale, « État de l'art », qui contient quelques travaux antérieurs dans ce domaine avec leurs résultats, soulignant leurs limites et leurs lacunes, sur la base desquels notre étude actuelle est construite et développée.

-Chapitre 3 : Conception

Ce chapitre décrit l'approche utilisée pour développer un modèle de prédiction de l'autisme. Il commence par présenter les détails de la structure générale du système proposé pour la détection de l'autisme et consacre une partie importante à l'explication de l'importance des réseaux neuronaux convolutifs (CNN) dans la classification des images, en mettant en évidence leurs modèles et leurs composants de base. Il expose également les fondements théoriques de l'approche proposée.

-Chapitre 4 : Implémentation et Résultats

Ce chapitre présente une implémentation concrète d'un modèle de classification basé sur l'apprentissage profond. Il détaille l'environnement de développement, les outils utilisés et l'organisation des données de formation et de test. L'évaluation du modèle est effectuée à l'aide de mesures classiques telles que la précision, la courbe d'apprentissage et la matrice de confusion. Certaines études antérieures dans le même domaine sont ensuite discutées, et le chapitre se termine par une analyse critique des résultats expérimentaux et leur comparaison pour évaluer les performances du système.

Chapitre 1

Généralités sur l'Autism

1.1 Introduction

Dans un monde caractérisé par la diversité et les différences, l'autisme est l'un des problèmes les plus graves auquel est confrontée la société moderne. En tant que trouble difficile qui déforme la capacité des gens à interagir et à communiquer, l'autisme pose un certain nombre de questions controversées concernant ses causes et ses types, tout en affectant la vie des gens et de leurs familles. Cette section visera à identifier les problèmes d'autisme sous différents angles, à commencer par la définition de ce terme et ses causes.

1.2 L'Autism : Définition et Enjeux

En considérant ce trouble, il convient de noter que l'autisme est un trouble qui interfère avec le comportement, la communication et l'interaction avec les gens. Ces états ont été observés pour la première fois dans les années 40, lorsque les scientifiques ont décidé qu'un certain nombre d'enfants présentaient un modèle d'interaction inhabituel. Depuis ce moment, la gamme des symptômes scientifiques de l'autisme a

largement augmenté en raison de laquelle le monde a vu une variété de méthodes de diagnostic pour les patients.

1.2.1 Définition des maladies chroniques

Une maladie chronique est une maladie qui persiste chroniquement, en général plus de trois mois. Les maladies chroniques courantes incluent : arthrite, asthme, le cancer, le diabète, la bronchopneumopathie chronique obstructive, ou encore des maladies virales comme l'hépatite C et le sida.

En médecine, le concept de maladie chronique s'oppose à celui de maladie aiguë : la maladie aiguë n'implique la plupart du temps qu'un seul organe et se résout avec le traitement, au contraire de la maladie chronique, qui se propage à plusieurs endroits du corps et répond peu aux traitements. [1]

Ces maladies ont causé la mort d'au moins 43 millions de personnes en 2021, soit 75% décès non pandémiques dans le monde. [2]

L'autisme fait partie de ces maladies dont nous parlerons.

1.2.1.1 Définition de l'autisme

L'autisme est un terme général pour désigner certaines affections liées au développement du cerveau. Les signes d'autisme se manifestent assez tôt dans la vie d'un jeune enfant, mais en pratique, l'autisme n'est souvent diagnostiqué qu'à un âge beaucoup plus avancé.

L'autisme est caractérisé par un déficit plus ou moins marqué des compétences en matière de relations sociales et de communication. En outre, un certain nombre de caractéristiques atypiques d'activité et de comportement peuvent être observées, à savoir : des problèmes avec le passage de l'une à l'autre activité, une focalisation sur les plus petits détails, des réactions externes anormales à propos de sensations.

Il existe une grande variation et une variation des besoins et des capacités des personnes autistes, qui peuvent également changer au fil du temps. Alors que certaines personnes peuvent réussir à vivre de manière indépendante, un certain nombre d'autres personnes dépendront de soins de soutien tout au long de leur vie. L'autisme touche souvent les opportunités éducatives et d'emploi. En outre, il peut générer un fardeau de stress pour les familles qui prennent en charge ces soins physiques et de soutien [3].

1.2.1.2 Définition des troubles du spectre autistique (TSA)

Le trouble du spectre de l'autisme (TSA) est caractérisé dans le Manuel diagnostique et statistique des troubles mentaux DSM-V comme un trouble neuro-développemental avec des déficits importants dans la communication, les interactions sociales et la présence de comportements, activités ou intérêts restreint et répétitif).

Une partie des compétences sociales essentielles pour le développement d'interactions sociales adéquates ont été décrites comme étant problématiques chez les patients souffrant du TSA, ces compétences incluent l'expression et la reconnaissance des sentiments, ainsi que le déficit en compétences sociales, qui sont considérées comme des indicateurs de la qualité de vie chez les enfants atteints de troubles du spectre autistique, et qui ne s'améliorent pas automatiquement au cours du développement par rapport aux enfants normaux.

Les difficultés augmentent à l'adolescence lorsque l'environnement devient plus complexe et requiert de plus grandes compétences sociales. Compte tenu de ces effets et de la nature permanente du trouble, des solutions doivent être trouvées pour faciliter la vie des adolescents touchés. [4]

1.2.1.3 Historique et évolution des connaissances sur l'autisme

-Bleuler **1911** introduit le terme autisme pour définir le retrait relationnel symptomatique de la schizophrénie à la fin du xix siècle Il fut ensuite utilisé par le psychiatre autrichien Leo Kanner pour désigner un syndrome spécifique de l'enfant qu'il nomme d'abord " perturbation autistique du contact affectif», puis «autisme infantile . Dans un article de Kanner publié en **1943** , il expose le profil clinique de onze enfants ayant pour dénominateur commun difficulté dans la dynamique de la relation et de la communication : " le trait fondamental de désordre est l'incapacité de ces enfants à élaborer des relations normales à l'égard des personnes et des situations (...) dès les premiers jours de leur vie ". [5]

-En **1945**, Hans Asperger a mis en évidence un groupe de symptômes combinant des difficultés d'interaction avec les autres, des intérêts restreints, une utilisation inappropriée du langage et des difficultés de coordination motrice.

-Dans les années **1980**, la psychiatre britannique Lorna Wing a suggéré que l'autisme n'était pas une condition binaire (présente ou absente seulement), mais plutôt une gamme de symptômes dont la gravité varie . Par exemple, les difficultés de communication sociale vont des problèmes d'interaction avec les autres à un retrait social sévère. Fort de cette constatation, Wing a émis l'hypothèse que l'autisme pourrait être plus répandu qu'on ne le pensait auparavant. [6]

-La figure **1.1** représente l'évolution des connaissances sur l'autisme.




FIGURE 1.1 – évolution des connaissances sur l'autisme.

1.2.1.4 Les symptômes de l'autisme

Cette maladie présente de nombreux symptômes dont la gravité varie d'une personne à l'autre, dont les suivants :

- Manque de capacité naturelle à communiquer visuellement, car ces enfants évitent de regarder leurs interlocuteurs dans les yeux et ne répondent pas aux appels, comme s'ils étaient sourds ou dans un autre monde, d'où le nom d'autisme, qui signifie se échapper de réalité. [7]

- Difficultés d'intégration sociale

- Difficulté à comprendre les sentiments

- Troubles du langage et retard de développement

- Répétition de certains comportements tels que des mots, des syllabes ou des mouvements

- Résistance au changement et difficulté d'adaptation aux changements de routine

-Troubles de la régulation sensorielle tels qu'hyper- ou hyposensibilité aux sons, aux odeurs, aux goûts, etc. [5]

1.2.1.5 Le diagnostic de l'autisme

Le diagnostic de l'autisme est le résultat d'un processus d'évaluation complexe réalisé par une équipe multidisciplinaire (médicale, psychologique, paramédicale) et porte sur différents aspects et comportements tels que : la nature et la gravité des troubles, le niveau de développement intellectuel , connaissance et communication, développement langagier et moteur, et savoir réaliser des activités, et domaine psychologique et émotionnel et aussi performance sensorielle... Elle repose sur :

- Observations : Réalisées à partir de questionnaires auprès de personnes proches de l'atteinte (notamment ses parents) ainsi que de professionnels qui l'entourent au quotidien dans les différents lieux qu'elle fréquente, comme la crèche, l'école ou le travail pour personnes âgées.

- Des tests standardisés : selon les différents domaines à évaluer (tests de langage, de motricité, etc.) qui sont adaptés à l'âge de l'individu, à ses caractéristiques de développement, à son comportement .Le contexte du test et les critères approuvés doivent être conformes aux recommandations de la Haute Autorité de Santé. [5]

1.2.2 Prévalence et Incidence

Au fil des années, les données ont montré une augmentation significative des diagnostics d'autisme et sont essentielles pour orienter les politiques de santé, planifier les services de soutien et prioriser la recherche visant à mieux comprendre les causes sous-jacentes de l'autisme.

1.2.2.1 Statistiques mondiales

La prévalence mondiale des troubles du neurodéveloppement (TDN) varie de 5% à 15% , avec des variations dans la gravité des symptômes. Les données officielles suggèrent que plus d'une personne sur 100 pourrait être diagnostiquée autiste. Pour des raisons qui ne sont pas entièrement claires, l'autisme est diagnostiqué plus souvent chez les garçons que chez les filles , à un taux de 4 garçons pour 1 fille. Le risque d'avoir un enfant autiste est 10 à 20 fois plus élevé dans les familles qui ont déjà un enfant atteint de cette maladie. De plus, l'autisme est plus fréquent chez les jumeaux identiques que chez les jumeaux non identiques. [5]

-Plus en détail, voici les résultats d'une étude menée en 2021 à partir de données recueillies depuis 2012 :

L'examen a porté sur 71 études, à partir desquelles 99 estimations de la prévalence de l'autisme ont été identifiées dans 34 pays. Les tailles d'échantillon variaient de 465 à 50 millions de participants, et la prévalence médiane était de 100 cas pour 10 000 personnes, avec une fourchette de 1,09 à 436 pour 10 000 personnes. La plupart des études ont été réalisées aux États-Unis et en Europe du Nord, et en plus d'études sont menées en Afrique et au Moyen-Orient. La majorité des recherches se sont concentrées sur les enfants, avec un petit nombre d'adultes. Les hommes ont montré des taux plus élevés que les femmes, avec un ratio allant de 0,8 à 6 hommes pour 1 femme. Le pourcentage de personnes atteintes d'autisme et de déficience intellectuelle varie de 0 % à 70 % selon les régions. [8]

-le tableau 1.1 représente la prévalence de l'autisme dans les différentes régions du monde de 2012 à 2021. [8]

TABLE 1.1 – Prévalence de l'autisme dans les différentes régions du monde de 2012 à 2021

Région	Estimation	Gamme	Médian
Amériques	30	465_8.129.270	54.960
Europe	31	1796_2.431.649	32.342
Pacifique Occidental	22	3300_51.529.338	19.349
Asie du Sud-Est	8	3964_28.070	8143
Méditerranée Orientale	6	998_837.655	30.754
Afrique	2	–	–
Tous	99	465_51.529 .338	31.000

Remarque : les mots-clés sont

-**Estimation** : Nombre d'études.

-**Gamme** : La valeur la plus basse et la plus haute observée.

-**Médiane** : valeur moyenne.

1.2.3 Facteurs de risque

Les recherches scientifiques menées sur l'autisme n'ont pas abouti à une conclusion définitive sur la cause directe pour cette maladie, bien que la plupart des recherches soulignent un facteur génétique qui a une influence sur le développement de ce trouble. Le taux d'infection est plus élevé chez les vrais jumeaux (issus d'un œuf) que chez les autres jumeaux (issus de deux ovules différents). Certaines radiographies modernes, telles que l'imagerie par fréquence magnétique MRI et PET, ont montré la présence de certains signes anormaux dans la structure du cerveau. Avec de nettes différences

dans le cervelet. [9]

Étant donné que le facteur génétique est le principal candidat à l'origine de l'autisme, les scientifiques ont mené plusieurs autres études pour arriver aux conclusions suivantes :

1.2.3.1 Facteurs génétiques

Les recherches en génétique suggèrent une composante héréditaire dans l'étiologie du trouble du spectre de l'autisme (TSA). Une méta-analyse de sept études sur des jumeaux estime que l'héritabilité de l'autisme se situe entre 60% et 90%. Par conséquent, les familles ayant déjà un enfant autiste présentent un risque accru d'avoir un autre enfant atteint du TSA. Il est également probable qu'il existe une possibilité d'avoir un enfant autiste parmi les proches de personne atteinte.

Certaines mutations génétiques ou altérations du génome augmentent le risque de développer un TSA. Lorsqu'un parent est porteur de ces variations, celles-ci peuvent être transmises à l'enfant, même si le parent lui-même ne présente pas de symptômes du trouble. Dans certains cas, l'autisme est associé à des pathologies génétiques spécifiques, telles que le syndrome de Rett ou le syndrome de l'X fragile.

Dans la majorité des cas, l'étiologie de l'autisme repose sur des altérations génétiques multiples affectant différentes régions du génome. Ces variations ne sont généralement pas suffisantes à elles seules pour provoquer le trouble, mais interagissent avec d'autres facteurs environnementaux pour moduler le risque de développement du TSA. [10]

1.2.3.2 Facteurs environnementaux

Des études indiquent que les facteurs environnementaux pourraient contribuer jusqu'à 50% à la variation du risque de trouble du spectre autistique (TSA). [11] Les chercheurs examinent la possibilité qu'il existe des facteurs environnementaux avant la

naissance, tels que des facteurs provoquant des malformations. D'autres se concentrent sur l'environnement postnatal ainsi que sur l'âge du père et de la mère, et la recherche indique, la pollution environnementale à laquelle l'enfant peut être exposé pendant sa phase sensible, comme les produits chimiques, les substances toxiques, peut affecter le développement de l'enfant, et celles-ci peuvent s'accumuler. Il pénètre dans le cerveau par le diaphragme, qui n'est pas encore complètement développé, provoquant des problèmes de développement, notamment l'autisme. [12]

1.2.3.3 Facteurs biologiques

Certains chercheurs affirment que ces facteurs sont liés à des cas de lésions cérébrales directes avant, pendant ou après la naissance, comme par exemple si la mère est infectée par une maladie infectieuse pendant la grossesse ou est exposée pendant la naissance au problème de manque d'oxygène, ou en cas d'accouchement difficile, ou utilisation de machines pendant le processus d'accouchement, ou d'autres facteurs tels que le fait que la mère soit exposée à une hémorragie avant l'accouchement, soit exposée à un accident ou soit vieille. de ces facteurs peuvent être des causes qui se chevauchent de l'autisme. [12]

1.3 L'utilisation des données médicales en santé

Dans le secteur de la santé, comme dans d'autres secteurs, mégadonnées extraites de différentes sources constitue une grande richesse qui peut contribuer de manière significative à l'amélioration des soins de santé, grâce aux algorithmes et à l'intelligence artificielle. [13]

Ces données sont générées non seulement pour le suivi des patients, mais également pour le diagnostic et le pronostic, ce qui rend leur analyse et leur gestion quelque peu complexes.

1.3.1 Types de données médicales

Les données médicales sont un vaste ensemble d'informations relatives à l'état d'un individu, depuis son diagnostic initial jusqu'aux résultats et images médicaux. Ces données jouent un rôle crucial dans le développement de nouvelles méthodes thérapeutiques et peuvent être classées en plusieurs catégories, dont les plus importantes sont :

1.3.1.1 Données démographiques

Le mot démographie est composé de deux mots grecs signifiant « description des personnes » et désigne généralement l'étude des populations et de leurs caractéristiques, notamment la croissance démographique, la mortalité et le vieillissement, et certaines caractéristiques comme : l'âge, le sexe, le lieu de naissance, la santé, l'éducation, la profession et la famille. Ainsi, les données démographiques désignent les informations obtenues grâce à ces caractéristiques et qui servent à examiner les changements et les comportements de la population, à établir des prédictions et des diagnostics. [14]

1.3.1.2 Données cliniques

Les données cliniques sont l'ensemble des données collectées par un médecin concernant le diagnostic, les symptômes et les résultats des tests médicaux d'un patient. [15] Par exemple, la pression artérielle et la glycémie, lorsque ces mesures normales sortent de la plage de référence, donnent des indications sur un état pathologique. Ici, le préfixe « hypo- » est utilisé pour une chute sévère du taux de sucre dans le sang et « hyper- » pour une augmentation. [16]

1.3.1.3 Données d'imagerie médicale

L'imagerie médicale est utilisée comme test préliminaire, pour confirmer ou infirmer un diagnostic suspecté. [17] Il s'agit d'un moyen d'obtenir des images des parties internes du corps humain. Pour ce faire, on utilise différentes techniques qui dépendent de l'interaction des rayonnements avec le corps, comme les rayons X, l'imagerie par résonance magnétique et les ultrasons. Pour mieux comprendre le fonctionnement du corps. [18]

1.3.1.4 Données de capteurs portables

Informations collectées à partir d'appareils portables intelligents pour les soins de santé personnels et la télémédecine, tels que des capteurs et d'autres appareils portables tels que des montres intelligentes. Ces outils numériques ont un énorme potentiel pour améliorer la capacité de diagnostiquer et de traiter avec précision les maladies et d'améliorer la prestation des soins de santé à un individu. Ils permettent également d'avoir une vue plus complète de la santé d'un patient grâce à l'accès aux données et donnent aux patients plus de contrôle sur leur santé, comme le diagnostic précoce des maladies et la gestion des maladies chroniques en dehors des établissements de soins de santé traditionnels. [19]

1.3.1.5 Données biologiques

Les données biologiques sont des collections d'indicateurs stockés dans des bases de données qui représentent des observations sur des systèmes biologiques complexes. Ces données sont mesurées à l'aide de diverses techniques expérimentales. [20] Elle est collectée grâce à des expériences scientifiques. Il contient des informations provenant de différents domaines de recherche tels que la protéomique, la génétique, etc. Ces données sont importantes car elles permettent la compréhension et l'interprétation de nombreux

phénomènes biologiques et facilitent une gestion plus flexible des maladies. [21]

1.3.2 Sources des Données Médicales

Les données auxquelles on se réfère et qui sont analysées lors de la réalisation d'une étude résident dans une ou plusieurs bases de données et constituent la « source de données ». [22]

1.3.2.1 Les bases médico-administratives

Certaines études portent sur les bases de données « médico-administratives », qui sont créées à des fins administratives ou économiques (assurances, comptabilité, soins de santé, etc.), dans le but d'utiliser les données collectées à des fins de recherche médicale. En plus des données démographiques telles que l'âge, le sexe, l'état il fournit également des bases de données avancées telles que des informations sur les services de soins ambulatoires (consultations médicales, médicaments, dispositifs médicaux, imagerie). [22]

1.3.2.2 Les dossiers patients et les bases des données hospitalières

Fichiers de soins qui recueillent diverses informations cliniques, paracliniques et démographiques sur les patients, telles que les résultats biologiques et l'imagerie radiologique. Certains hôpitaux ont collecté cette grande quantité de données et de détails dans des entrepôts de données au sein de l'hôpital qui peuvent être réutilisés à des fins de recherche. [22]

1.3.2.3 Les registres

Recueil de tous les cas d'accidents chez les patients présentant des maladies, qu'elles soient spécifiques, comme le cancer et l'accident vasculaire cérébral, ou de cause incon-

nue, comme la fibrose pulmonaire. Ces dossiers permettent d'identifier les caractéristiques des patients et de suivre leur évolution dans le temps. Les registres de maladies peuvent être internationaux, ou limités à une zone géographique spécifique ou à un certain nombre d'établissements de santé, et ne peuvent inclure que les patients qui acceptent de faire partie du registre. [22]

1.4 Conclusion

Ainsi, l'autisme est un défi complexe qui demande des efforts conjoints de plusieurs secteurs. Une compréhension plus approfondie de ce qui provoque et fait le type du trouble peut aider à générer des approches de diagnostic et de traitement plus avancées. De plus, informer les individus de l'efficacité de passer du temps avec des personnes atteintes d'autisme en tant que partie intégrante de la société aident à créer une société favorable à la tolérance.

Chapitre 2

Techniques d'intelligence artificielle pour détecter l'autisme

2.1 Introduction

Le monde d'aujourd'hui est témoin d'une révolution technologique massive, menée par l'intelligence artificielle (IA), qui est devenue un élément important de nos vies. Bien qu'il n'existe pas de définition précise de ce terme, il fait généralement référence à la capacité des machines à simuler l'intelligence humaine, grâce à diverses techniques.

Dans cette section, nous discuterons de l'intelligence artificielle et de son développement historique, menant à l'âge d'or dans lequel nous vivons aujourd'hui. Nous passerons également en revue ses différentes applications dans le domaine du diagnostic de l'autisme, en nous concentrant sur l'utilisation des techniques d'apprentissage profond et de réseaux neuronaux. Cela démontrera le rôle de l'intelligence artificielle dans divers secteurs, notamment le secteur médical, qui cherche à améliorer le diagnostic et le traitement.

2.2 Introduction à l'intelligence artificielle

À la lumière du développement technologique rapide, l'intelligence artificielle est apparue comme l'un des outils les plus importants pour le développement humain et a contribué à modifier l'équilibre entre les individus. Ses applications ont connu un succès remarquable dans divers domaines, tel que la médecine au traitement.

2.2.1 Définition de l'intelligence artificielle

L'intelligence artificielle (IA) est une branche de l'informatique qui vise à aider les humains à atteindre de meilleures performances en sciences et en technologie en développant des systèmes capables de simuler l'intelligence humaine et des programmes capables d'auto-apprentissage, de résolution de problèmes et de prise de décision. [23]

-La figure suivante 2.1 montre les sous-domaines de l'intelligence artificielle.




FIGURE 2.1 – Les domaines de l'IA.
[24]

2.2.2 Evolution historique

Maintenant que nous connaissons le concept d'intelligence artificielle, nous allons maintenant voir son développement historique. Qui a connu des progrès remarquables et une large diffusion dans le monde.

-Epoque 01 (1940-1960) : en 1943, un chercheur a publié le premier modèle mathématique d'un réseau neuronal dans la revue « A Logical Calculus of the Ideas Immanent in Nervous Activity ».

-Epoque 02 (1960-1970) : Durant cette période, l'enthousiasme pour l'intelligence artificielle a diminué. En raison des limitations technologiques et de la mémoire informatique insuffisante, les chercheurs ont eu du mal à comprendre les enjeux de l'intelligence artificielle.

-Epoque 03 (1970-1980) : Les systèmes experts prennent désormais des décisions basées sur des bases de données. L'invention des microprocesseurs à la fin des années 1970 a également donné un nouvel élan à l'intelligence artificielle.

-Epoque 04 (1980-1990) : L'intelligence artificielle à cette époque a connu une autre période de ralentissement, en raison du coût élevé des infrastructures technologiques et de la préférence pour des solutions simples à divers problèmes. [25]

-Epoque 05 (depuis 2010) : Cette époque a été témoin d'un tournant pour l'intelligence artificielle, marqué par l'explosion de l'apprentissage profond, des réseaux neuronaux et du big data. Plusieurs projets l'ont prouvé, notamment : Projet Google Brain : Systèmes capables de reconnaître des objets dans des vidéos sans assistance humaine. En 2011, le système Watson d'IBM a battu les champions humains à Jeopardy, démontrant sa capacité à traiter et à comprendre de grandes quantités d'informations en langage naturel. En 2016, le programme AlphaGo de DeepMind a remporté la victoire sur Lee Sedol au jeu de Go, Ce qui a démontré la capacité de l'intelligence artificielle à maîtriser des jeux considérés comme trop complexes pour les machines. À

la fin de la décennie, l'intelligence artificielle a commencé à s'étendre à divers domaines, tels que la santé, la finance et d'autres.

-Epoque 06 (Les Années 2020) : Les années 2020 ont vu l'émergence de modèles d'IA révolutionnaires comme GPT-3 d'OpenAI, qui a marqué une nouvelle explosion dans le traitement du langage naturel avec ses vastes capacités de génération de texte, de traduction et de programmation. Avec le lancement de GPT-4, l'IA a franchi une nouvelle étape en intégrant des techniques comme DALL-E pour générer des images à partir de texte. [26]

2.2.3 Types d'intelligence artificielle

L'intelligence artificielle est généralement classée en deux types : forte ou faible.

- L'intelligence artificielle forte vise à développer une machine dotée de capacités cognitives proches de celles des humains, capable de trouver des solutions à des problèmes sans aucune intervention humaine.
- L'intelligence artificielle faible consiste à développer des machines capables de répondre à un problème spécifique et capables de simuler la pensée humaine grâce aux données et à l'assistance humaine. [27]

2.2.4 Applications de l'intelligence artificielle dans divers domaines

L'intelligence artificielle a prouvé ses capacités dans de nombreux secteurs, notamment :

- Voitures : véhicules autonomes et véhicules utilisant des technologies de communication
- Santé : Prédiction et diagnostic des maladies et chirurgie d'assistance
- Défense et Aviation : Cybersécurité

- Tourisme : E-tourisme et assistants virtuels
- Banque : Chatbots intelligents pour le service client et robo-advisors pour la gestion de patrimoine et le conseil financier personnalisé [28]
- etc.

2.2.5 La relation entre le big data et l'intelligence artificielle

Pour comprendre la relation entre ces deux systèmes, il est nécessaire de revenir à la définition de l'intelligence artificielle, qui désigne l'ensemble des technologies capables de produire des capacités similaires à celles des humains. Pour ce faire, la machine doit intégrer une grande quantité de données pour apprendre et assimiler des modèles algorithmiques afin de produire des résultats précis ou proche de la précision.

Le Big Data (mégadonnées) a un impact considérable plus il y a de données, plus la machine est capable de maîtriser l'apprentissage et l'inférence, et ainsi de réussir à imiter les fonctions cognitives de l'intelligence humaine. C'est pour cette raison que nous disons que le big data et l'intelligence artificielle forment ensemble un lien appelé « intelligence du big data ». [29]

2.3 Bases de l'apprentissage automatique

Les fondamentaux de l'apprentissage automatique sont l'ensemble des concepts fondamentaux utilisés pour comprendre comment fonctionnent les systèmes intelligents qui apprennent à partir des données. Cette section rassemble les concepts de base associés aux différents types d'apprentissage, ainsi que les principaux algorithmes utilisés.

Dans le contexte de la détection précoce de l'autisme, ces connaissances sont essentielles pour développer des modèles capables d'extraire automatiquement des caractéristiques discriminantes à partir d'images faciales, garantissant ainsi des prédictions

fiables.

2.3.1 Définition de l'apprentissage automatique

L'apprentissage automatique, ou ML (Machine Learning), est un type d'intelligence artificielle qui permet aux ordinateurs d'apprendre sans programmation explicite ; Cela est réalisé en développant, en analysant et en programmant des méthodes qui permettent aux machines d'effectuer des tâches associées à l'intelligence artificielle grâce au processus d'apprentissage.

Ce dernier nous permet d'avoir un système qui s'améliore en fonction de l'environnement, des expériences et des résultats. Dans le domaine médical, l'analyse des données médicales est également autorisée. [30]

2.3.2 Types d'apprentissage automatique

Ce domaine repose sur trois principaux types d'apprentissage, chacun d'entre eux offrant des moyens de résoudre des problèmes complexes, et la figure 2.2 l'illustre cela.




FIGURE 2.2 – Apprentissage automatique.

2.3.2.1 Apprentissage supervisé

L'apprentissage supervisé est un type d'apprentissage automatique dans lequel un algorithme informatique est formé à l'aide d'exemples de données pour accomplir une tâche spécifique.

Les algorithmes utilisent des données d'entraînement pour apprendre à prédire de nouvelles données. Les algorithmes apprennent en comparant leurs prédictions.

Cette approche est utilisée pour de nombreuses tâches, notamment la classification des données, la reconnaissance d'images. La figure suivante 2.3 illustre les types d'apprentissage supervisé.




FIGURE 2.3 – Apprentissage Supervisé.

2.3.2.2 apprentissage non supervisé

L'apprentissage non supervisé est une branche de l'apprentissage automatique qui analyse et regroupe des données non étiquetées et découvre des modèles et des relations cachés sans intervention humaine.

Les algorithmes peuvent utiliser diverses techniques, telles que la corrélation, le clustering et la création de modèles, pour découvrir des structures cachées dans les données. Ce type d'apprentissage est particulièrement utile lorsqu'il s'agit de traiter

de grandes quantités de données non étiquetées, comme dans le cadre d'un diagnostic précoce ou de l'exploration d'indices visuels subtils dans des images faciales. La figure suivante 2.4 illustre les types d'apprentissage non supervisé.




FIGURE 2.4 – Apprentissage non Supervisé.

2.3.2.3 apprentissage semi-supervisé

L'apprentissage semi-supervisé est une approche efficace pour exploiter les données étiquetées et non étiquetées afin d'adapter le modèle, ce qui donne lieu à des modèles d'apprentissage automatique plus puissants et plus flexibles en exploitant à la fois l'apprentissage supervisé et non supervisé dans le processus de formation de l'algorithme.

Cette méthode d'apprentissage consiste à créer un modèle pondéré capable de prédire les réponses à des données similaires qui n'ont pas encore été étiquetées. La figure suivante 2.5 illustre le principe de l'apprentissage semi-supervisé.

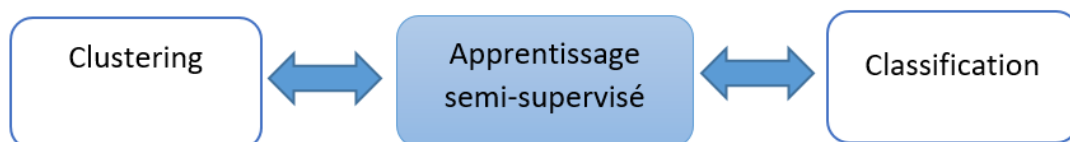


FIGURE 2.5 – apprentissage semi-supervisé.

2.3.2.4 Apprentissage par Renforcement

L'apprentissage par renforcement est une technique d'apprentissage automatique qui permet de former des modèles d'IA. Le modèle, appelé « agent », qu'il s'agisse d'une machine ou d'un programme, apprend en développant des compétences de prise de décision à travers des essais et des erreurs successifs dans un environnement dynamique. Au fil du temps, le Agent acquiert l'expérience nécessaire pour développer la stratégie de prise de décision idéale ,comme illustré par la Figure 2.6 .

Les algorithmes d'apprentissage par renforcement ont un large éventail d'applications, telles que la gestion de la robotique, l'optimisation de la chaîne d'approvisionnement, les réseaux intelligents et de nombreux autres domaines. [31]




FIGURE 2.6 – Apprentissage par Renforcement.

2.3.3 Algorithmes de base pour l'apprentissage automatique

Les algorithmes de base de l'apprentissage automatique sont des méthodes fondamentales qui permettent aux systèmes d'apprendre à partir des données et de faire des prédictions ou des classifications. Chacun de ces algorithmes a ses avantages en fonction de la nature des données et du problème à résoudre. Par exemple, les machines à vecteurs de support sont efficaces pour les petites dimensions, tandis que les réseaux neuronaux sont plus adaptés aux données complexes telles que les images. Parmi ces

algorithmes, nous citons :

2.3.3.1 Arbre de décision

Les arbres de décision sont des modèles d'arbres utilisés comme modèle prédictif dans un large éventail de domaines, notamment les statistiques, l'exploration de données et l'apprentissage automatique.

Comme dans la figure suivante 2.6 , il fonctionne en divisant les données en branches en fonction de leurs propriétés, conduisant à des résultats finaux sous la forme de « feuilles ». [32]




FIGURE 2.7 – Exemple d'arbre de décision.

2.3.3.2 Réseaux à vecteurs de support

Les algorithmes à vecteurs de support (SVM) sont un groupe d'algorithmes d'apprentissage supervisé similaires utilisés dans la classification et la régression.

Ces algorithmes créent un modèle qui prédit si un nouvel échantillon appartient à l'une des deux classes, en fonction d'un ensemble d'échantillons d'entraînement étiquetés. [32]




FIGURE 2.8 – Réseaux à vecteurs de support.

2.3.3.3 Réseau bayésien

Un réseau bayésien, également connu sous le nom de réseau de croyances ou de modèle graphique acyclique dirigé, est un modèle graphique probabiliste qui utilise un graphe acyclique dirigé pour décrire un ensemble de variables aléatoires et leur indépendance conditionnelle. Par exemple, un réseau bayésien peut être utilisé dans nos recherches pour illustrer les associations probabilistes entre l'autisme et ses symptômes.

Il peut également être utilisé pour calculer la probabilité d'avoir certaines maladies en fonction des symptômes. [32]

2.3.4 Limites de l'apprentissage automatique

Parfois, les programmes d'apprentissage automatique ne parviennent pas à fournir les résultats escomptés. Cela est dû à plusieurs raisons, notamment : une mauvaise collecte de données, des problèmes de confidentialité des données, une mauvaise utilisation de logiciels ou d'algorithmes, un manque de compétences nécessaires, un manque

de ressources, etc. Par exemple, en 2018, une voiture autonome Uber n'a pas réussi à identifier un piéton, provoquant sa mort. Vous trouverez ci-dessous une discussion sur certaines des principales limites de l'apprentissage automatique :

A. Biais : une méthode d'apprentissage automatique basée sur les clients existants peut ne pas prédire les nouveaux besoins des clients qui ne sont pas présents dans les données de formation actuelles. L'apprentissage automatique absorbe les mêmes biais répandus dans la société lorsqu'il est appliqué à la collecte manuelle de données. Par exemple, une méthode d'apprentissage automatique testée pour mesurer le risque criminel s'est avérée biaisée en faveur des personnes noires. En 2014, Google Images signalait les personnes à la peau noire. [33]

B. Éthique : L'apprentissage automatique nécessite des données valides et une documentation minutieuse des algorithmes en raison de biais linguistiques, par exemple. Un autre biais éthique peut être observé dans le secteur de la santé. L'apprentissage automatique peut résoudre ces problèmes dans le domaine de la santé en s'attaquant aux biais gourmands. [33]

C. Hardware : Les GPUs, unités de traitement graphique améliorées par l'IA, se sont avérés être la clé de la formation commerciale à grande échelle dans le cloud, surpassant les capacités des CPUs. [33]

2.4 Apprentissage profond

L'apprentissage profond est l'une des pierres angulaires de l'intelligence artificielle moderne. Cette section présente les bases de cette approche, en se concentrant sur ses composants clés. Ces éléments seront analysés dans le cadre de la classification des images médicales, notamment celles utilisées dans le dépistage des troubles du spectre autistique.

2.4.1 Définition de l'apprentissage profond

L'apprentissage profond, ou Deep Learning, est une branche de l'intelligence artificielle qui utilise des réseaux neuronaux artificiels profonds pour définir des règles plus complexes. Il s'agit d'une technique permettant d'entraîner des machines à imiter la manière dont les neurones du cerveau humain traitent et apprennent les informations.

La technologie d'apprentissage profond est utilisée dans de nombreux domaines tels que la reconnaissance d'images, la traduction automatique, les voitures autonomes et le diagnostic médical. [34]

2.4.2 Histoire de l'apprentissage profond

L'apprentissage profond remonte aux années 1940 et est toujours d'actualité aujourd'hui. Voici un aperçu de ce développement :

- **1940-1960** : McCulloch et Pitts ont posé les bases de l'apprentissage profond avec leur modèle de neurone formel en 1943. Plus tard, en 1958, Frank Rosenblatt a créé le perceptron, mais sa capacité à gérer des problèmes complexes était limitée par son architecture monocouche.

- **1960-1980** : Durant cette période, les méthodes symboliques et les systèmes experts ont dominé l'intelligence artificielle, marginalisant les réseaux de neurones en raison de leur incapacité à résoudre des problèmes complexes et du manque de puissance de calcul nécessaire pour les entraîner sur de grandes quantités de données.

- **1980-2000** : L'apprentissage profond a connu une période de désintérêt pendant plusieurs années, en raison du manque de puissance de calcul suffisante pour entraîner les réseaux neuronaux profonds.

Depuis 2000 : l'apprentissage profond a connu un essor considérable, porté par des avancées significatives en matière de puissance de calcul et d'accès à des ensembles de données massifs. Cette renaissance a été soutenue par des algorithmes d'appren-

tissage améliorés, notamment les réseaux neuronaux convolutifs (CNN) et les réseaux neuronaux récurrents (RNN). Ils ont démontré des performances exceptionnelles dans divers domaines, tels que la vision par ordinateur, le traitement du langage naturel, la reconnaissance vocale et bien d'autres. [34]

2.4.3 Objectif d'apprentissage profond

Voici pourquoi l'apprentissage profond est si important et largement utilisé :

- Extraire des modèles et identifier des tendances difficiles à détecter pour les humains ou les technologies informatiques.

- Les informations sont stockées sur l'ensemble du réseau neuronal plutôt que dans une base de données.

- Les réseaux bien formés peuvent tirer des conclusions même avec des données incomplètes ou inintelligibles.

- Un réseau neuronal peut continuer à fonctionner efficacement même si certaines cellules (neurones) tombent en panne.

- Les réseaux de neurones artificiels apprennent et prennent des décisions en analysant des événements similaires.

- Les réseaux neuronaux artificiels ont la puissance numérique d'effectuer de nombreuses tâches simultanément. [34]

2.4.4 Les réseaux de neurones

L'idée des réseaux de neurones artificiels a été inspirée par le fonctionnement du cerveau humain. Il est constitué d'un groupe de neurones, ou de ce que nous appelons des nœuds dans notre concept, et de plusieurs couches successives, chacune constituée de plusieurs neurones, de telle sorte que chaque neurone reçoit des entrées, puis elles sont multipliées par des poids qui représentent l'importance de chaque entrée, puis elles

sont additionnées. Si cette somme dépasse une certaine valeur d'activation, le neurone est activé et transmet les sorties. Les neurones sont organisés en couches : une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Les informations circulent de la couche d'entrée vers les couches cachées, puis vers la couche de sortie. Les poids des connexions entre les neurones sont ajustés pendant le processus d'apprentissage pour minimiser les erreurs entre les résultats réels et les résultats attendus par le réseau. [35]




FIGURE 2.9 – Un schéma du fonctionnement d'un réseau neuronal.
[35]

2.4.5 Les techniques d'apprentissage profond

L'apprentissage profond utilise différents types d'architectures de réseaux neuronaux, chacune spécifiquement conçue pour des tâches spécifiques. Les principaux types sont les suivants :

2.4.5.1 Les réseaux neuronaux récurrents (RNN- recurrent neural network)

Un réseau neuronal récurrent est un type de réseau neuronal artificiel constitué d'unités interconnectées qui interagissent de manière non linéaire et caractérisé par la présence d'au moins un cycle dans sa structure.

Ces réseaux sont particulièrement adaptés au traitement de données sérielles (ou chronologiques). Il calcule sa sortie à l'instant (t) en fonction de l'entrée correspondante (X_t) et de l'état de la couche cachée à l'instant précédent.

De cette manière, les réseaux neuronaux récurrents développent un état interne qui agit comme une mémoire à court terme, leur permettant de prendre en compte les dépendances temporelles des variables d'entrée. [36]




FIGURE 2.10 – Réseaux RNN.

2.4.5.2 Les réseaux adversaires génératifs (GAN)

Les réseaux antagonistes génératifs (GAN) sont une technique d'intelligence artificielle qui permet Pour créer de nouvelles instances d'un objet. En utilisant deux réseaux neuronaux concurrents - un générateur, qui crée de nouvelles données, et un

discriminateur, qui évalue l'authenticité des données, les GAN sont utilisés dans de nombreux domaines, tels que la création d'images et de vidéos de haute qualité, la colorisation d'images en noir et blanc, la détection et la correction des distorsions, la création d'œuvres d'art, la synthèse audio et même en médecine pour générer des images médicales synthétiques pour former les réseaux neuronaux. [34]

2.4.5.3 Les réseaux neuronaux convolutifs (CNN)

Un réseau neuronal convolutif, ou CNN, est un type spécialisé de réseau neuronal conçu principalement pour le traitement de données d'image bidimensionnelles, bien qu'il puisse être utilisé avec des données unidimensionnelles et tridimensionnelles. Ces réseaux sont capables d'apprendre à extraire des caractéristiques locales, c'est-à-dire des structures qui se répètent dans toute l'image.

Les CNN sont largement utilisés dans diverses applications, notamment pour les données complexes telles que la reconnaissance d'images, le traitement audio, la détection de mots-clés, la détection d'objets, la conduite autonome, la génération de données synthétiques, etc. [34]




FIGURE 2.11 – Réseaux CNN.

2.4.6 La différence entre l'apprentissage automatique et l'apprentissage profond

L'apprentissage automatique et l'apprentissage profond sont deux branches de l'intelligence artificielle qui permettent aux machines d'acquérir des connaissances et d'effectuer des tâches complexes. Bien qu'ils partagent l'objectif général d'apprendre à partir des données, ils diffèrent fondamentalement dans les approches et les techniques utilisées pour atteindre cet objectif. Dans le tableau suivant, nous passerons en revue les différences les plus importantes entre ces deux branches importantes :

TABLE 2.1 – Comparaison entre l'apprentissage automatique et l'apprentissage profond

Critère	Apprentissage automatique	Apprentissage profond
Organisation des données	Données structurées	Données non structurées
Base de données	Limitées ou contrôlables	Supérieur à 1 million de données (besoin de méga données)
Type d'entraînement	Entraînement par l'humain obligatoire	Apprentissage autonome (sans intervention humaine)
Algorithme utilisé	Algorithme modifiable	Réseaux de neurones (ANN)
Domaines d'application	Actions routinières simples (marketing en ligne, chatbot, vente...)	Tâches complexes (cybersécurité, assistant vocal, création de contenu...)
Adaptabilité aux données	Atteint un plateau de performance avec une quantité de données limitée	Plus les données sont nombreuses, meilleures sont les performances (pas de limitation théorique connue)
Amélioration des performances	Nécessite intervention humaine pour s'améliorer progressivement	Amélioration automatique des performances avec les données, parfois dépasse même la performance humaine
Représentation des données	Données structurées traditionnelles	Représentation via les réseaux de neurones

2.5 la détection de l'autisme

la détection de l'autisme (ou la détection des troubles du spectre autistique (TSA)) est un processus visant à identifier les premiers signes d'autisme chez les enfants ou les adultes. Elle s'appuie sur : la surveillance des comportements répétitifs et des interactions sociales à l'aide de technologies avancées.

2.5.1 L'importance de détecter l'autisme

Les recherches suggèrent qu'il est possible de détecter certains signes d'autisme à un stade précoce, bien que la fiabilité augmente avec l'âge. C'est pourquoi c'est si important :

Intervention précoce : Plus tôt l'autisme est détecté, plus tôt des interventions (telles que la thérapie comportementale ou langagière) peuvent être mises en œuvre, ce qui améliore considérablement les compétences sociales, cognitives et de communication, car la plasticité du cerveau est la plus élevée au cours des premières années de la vie.

Améliorer la qualité de vie : une intervention précoce et des soins appropriés sont essentiels pour réduire les symptômes et améliorer l'intégration sociale.

Accompagner les familles : Un diagnostic précoce permet aux familles de mieux comprendre les besoins de leurs enfants et de parvenir à des solutions adaptées.

2.5.2 Comment détecter l'autisme

La détection de l'autisme implique plusieurs méthodes, notamment :

Observation clinique : évaluation directe du comportement d'un enfant dans différents contextes de vie.

Entretiens structurés : Entretiens menés auprès des parents pour recueillir des

informations sur l'enfant.

Techniques avancées : Utilisation de l'apprentissage automatique et de l'apprentissage profond pour analyser des données comportementales, audio ou visuelles.

Analyse d'image : utilisation de réseaux neuronaux convolutifs (CNN) pour traiter des images ou des vidéos de visages ou d'expressions dans le but de détecter des anomalies comportementales dans l'autisme.

Capteurs et données biométriques : en utilisant des capteurs de mouvements oculaires, des capteurs de gestes ou encore des retours physiologiques, des réponses physiologiques (comme les variations de fréquence cardiaque).

2.6 le futur de l'apprentissage profond dans le diagnostic médical

L'avenir de l'apprentissage profond dans le diagnostic médical est très prometteur, les avancées technologiques faisant déjà progresser les techniques de diagnostic. Voici un aperçu des tendances et des opportunités futures :

Des modèles plus efficaces : l'architecture d'apprentissage profond s'améliore constamment, permettant un diagnostic plus rapide et plus précis. Par exemple, des modèles tels que les réseaux neuronaux graphiques (GNN) présentent des performances supérieures pour des tâches plus complexes, telles que l'analyse d'images médicales ou la modélisation d'interactions moléculaires.

Intégration de données multimodales : Intégration de différents types de données (imagerie, signaux biologiques, données génomiques, etc.) pour fournir un diagnostic plus complet. Par exemple, le modèle sera capable d'analyser simultanément des images IRM cérébrales, des données génétiques et des signaux EEG pour diagnostiquer des troubles neurologiques.

Intégration avec l'intelligence artificielle générale (AGI) : à mesure que l'IA évolue vers des formes plus avancées, les algorithmes d'apprentissage profond peuvent intégrer des capacités de raisonnement et de prise de décision d'une manière qui peut être considérée comme humaine. Exemple : Système : Poser des questions au patient, analyser ses réactions et adapter le diagnostic.

Collaboration homme-machine : les médecins utiliseront des outils d'IA comme assistants intelligents pour vérifier ou compléter leurs diagnostics. Exemple : Diagnostic : un radiologue utilise un modèle d'apprentissage profond pour détecter des anomalies qu'il aurait pu manquer.

Analyse avancée d'images médicales : l'apprentissage profond est déjà capable d'interpréter des images médicales (radiographies, IRM, tomodensitométries, etc.) avec une précision surpassant celle de l'œil humain. À l'avenir, cela permettra une détection plus précoce et plus précise du cancer, des maladies neurologiques, des blessures et d'autres anomalies.

Réduire les erreurs de diagnostic : en automatisant l'analyse des données et en mettant en évidence des informations qui pourraient autrement échapper à l'attention humaine, l'apprentissage en profondeur contribuera à réduire les erreurs de diagnostic.

Flux de travail optimisé : les tâches d'analyse de routine permettront aux professionnels de la santé de se concentrer sur des aspects plus complexes des soins aux patients.

Diagnostic à distance : Associé à la télémédecine, l'apprentissage profond permettra aux experts d'analyser les données médicales et de diagnostiquer les maladies à distance, améliorant ainsi l'accès aux soins de santé, en particulier dans les zones rurales ou mal desservies.

Santé mobile : les capteurs IoT fonctionneront en collaboration avec l'intelligence artificielle pour surveiller les patients de manière plus précise et continue.

2.7 État de l'art

Afin de mieux situer nos travaux de recherche dans le contexte scientifique actuel, il est nécessaire de procéder à une revue des travaux antérieurs liés au diagnostic des troubles du spectre autistique (TSA). Cette section vise à présenter des programmes d'études, qu'ils soient traditionnels ou basés sur des technologies modernes.

Nous commencerons par explorer les approches cliniques classiques qui ont longtemps constitué la base du diagnostic de l'autisme. Ensuite, nous discuterons de certaines études récentes sur l'apprentissage profond, qui offrent de nouvelles perspectives sur la détection précoce et automatisée des troubles du spectre autistique. Cet aperçu mettra en évidence les progrès réalisés et les limites actuelles.

2.7.1 Méthodes traditionnelles

Dans le passé, le diagnostic de l'autisme reposait sur des méthodes cliniques classiques, qui reposaient sur l'observation directe du comportement, des entretiens approfondis avec les parents et l'utilisation de tests psychologiques standardisés et même basés sur l'apprentissage automatique. Ces méthodes, qui se sont imposées dans le domaine médical, ont permis de détecter les premiers signes de l'autisme.

Étude : Cette étude visait à développer un modèle d'apprentissage automatique pour prédire les troubles du spectre autistique (TSA) à l'aide d'algorithmes tels que SVM et MLP. Les résultats ont été les suivants :. [37]

TABLE 2.2 – Résultats de la prédiction des troubles du spectre autistique à l'aide de techniques d'apprentissage automatique

Modèle	Précision (%)	Taux d'erreur (%)	Limites et défis
MLP	75.11	24.89	— données déséquilibrées. — Complexité du réglage des paramètres.
SVM	80.43	19.57	— algorithme complexe.

2.7.2 méthodes modernes

Avec l'avènement de l'intelligence artificielle et la disponibilité croissante des données biomédicales, de nouvelles méthodes sont apparues pour améliorer la précision et la rapidité du diagnostic de l'autisme. Ces méthodes modernes, basées sur l'apprentissage profond, permettent d'analyser automatiquement des données complexes (images, signaux cérébraux, comportements enregistrés, etc.) afin d'identifier les caractéristiques pertinentes associées aux troubles du spectre autistique. Aujourd'hui, ces méthodes sont devenues une alternative aux méthodes traditionnelles.

Étude 1 : Une équipe de recherche dirigée par Israr Ahmad de l'Université de Beihang, en Chine, d'Okara, au Pakistan, et de Vaasa, en Finlande, a publié en 2024 une étude intitulée « Détection des troubles du spectre autistique à l'aide d'images faciales : comparaison des performances des réseaux neuronaux convolutionnels pré-entraînés », qui visait à évaluer certains modèles d'apprentissage profond. [38] Les résultats ont été les suivants :

TABLE 2.3 – Comparaison des performances des modèles pour le diagnostic du TSA

Modèle	Précision (%)	Taux d'erreur (%)	Limites et défis
VGG16	81	19	— Taille du modèle très grande (144 millions de paramètres), ralentissant l'entraînement. — Sensible au surapprentissage avec de petits ensembles de données. — Peu adapté aux applications en temps réel en raison de sa lenteur.
AlexNet	75	25	— Architecture ancienne avec une faible capacité d'apprentissage des caractéristiques complexes. — Précision la plus faible parmi tous les modèles comparés.

Étude 2 : Une équipe de recherche de l'Université de Lahore au Pakistan, dirigée par Bawar Khan, Sohail Masood et Arsalan Akram, a publié en 2024 une étude intitulée « Détection des troubles du spectre autistique chez les enfants à l'aide de modèles d'apprentissage profond basés sur l'image faciale ». L'étude visait à évaluer plusieurs modèles d'apprentissage profond, dont ResNet50, qui présentait l'inconvénient de ne pas reconnaître les caractéristiques subtiles des images avec un éclairage imparfait. Cette étude s'est appuyée sur un ensemble de données de 2 940 images d'enfants âgés de 2 à 14 ans, réparties uniformément parmi les enfants autistes . [39] Le résultat est le suivant :

TABLE 2.4 – Résultat de performance du modèle ResNet50

Modèle	Précision (%)	Taux d'erreur (%)	Limites et défis
ResNet50	82	18	— Ne convient pas aux petits ensembles de données.

2.8 Conclusion

Nous avons conclu de cette étude que les technologies d’IA sont des outils puissants et efficaces dans le domaine du diagnostic des maladies. Ses diverses applications dans le diagnostic de l’autisme ont été passées en revue. À mesure que les modèles d’IA continuent d’évoluer, nous nous attendons à voir davantage d’innovations et d’applications pratiques qui contribuent à améliorer le diagnostic et le traitement.

Cependant, nous devons en être conscients pour tirer le meilleur parti de l’IA. Nous devons nous concentrer sur l’amélioration de la qualité des données utilisées dans la formation et sur le développement d’algorithmes plus efficaces pour garantir la fiabilité des résultats.

Chapitre 3

Conception

3.1 Introduction

Dans ce chapitre, nous passons en revue la contribution technique que nous avons développée dans le cadre de ce travail, à savoir la conception d'un modèle basé sur des techniques d'apprentissage profond pour détecter les troubles autistiques à partir d'images faciales. Ce modèle vise à améliorer la précision des prédictions en utilisant des structures de réseaux neuronaux convolutifs efficaces, en exploitant des modèles pré-entraînés sur de grands ensembles de données. Ce système repose sur une approche systématique qui combine les étapes de classification. Ce travail représente une tentative de fournir une solution pratique sur laquelle on peut compter dans des contextes médicaux ou de recherche visant à soutenir le diagnostic précoce de l'autisme.

3.2 Architecture générale du système proposé

Le système proposé consiste en une série d'étapes visant à traiter les images du visage pour détecter les troubles autistiques. Le système commence par l'étape de saisie des données, où un ensemble d'images collectées à partir de deux sources différentes

est téléchargé et traité à travers plusieurs étapes préliminaires pour garantir leur qualité et leur exactitude. L'étape de prétraitement est suivie de l'étape d'extraction des caractéristiques, qui est effectuée par des réseaux de neurones convolutifs (CNN) qui analysent les images et extraient les caractéristiques importantes.

Le système s'appuie sur plusieurs sous-modèles tels que ResNet50V2, InceptionV3 et VGG16, qui ont été utilisés pour extraire les caractéristiques des images avec précision et efficacité. Ces modèles sont basés sur une architecture profonde capable de reconnaître des motifs complexes dans les images.

Enfin, le modèle de classification produit un résultat final, qui détermine si l'image représente une personne autiste ou non.

la figure suivante 3.1 représente un dessin simplifié de ces étapes de base.




FIGURE 3.1 – Flux de travail pour la détection des troubles du spectre autistique à l'aide de l'apprentissage profond.

3.3 Apprentissage par transfert

Technique d'apprentissage automatique où un modèle pré-entraîné, souvent formé sur un grand jeu de données tel qu'ImageNet, sert de point de départ à une nouvelle tâche. L'idée de base est d'exploiter les connaissances acquises par le modèle à partir

d'un grand jeu de données pour les appliquer à un jeu de données plus restreint. Cette approche est particulièrement utile lorsque le jeu de données cible ne contient pas suffisamment de données .

3.3.1 Apprentissage par transfert versus ajustement fin (Fine-Tuning)

L'apprentissage par transfert diffère de l'ajustement fin. Tous deux réutilisent des modèles d'apprentissage préexistants, plutôt que d'en former de nouveaux. Mais les similitudes s'arrêtent là. L'ajustement fin consiste à prendre un modèle précédemment entraîné sur une tâche générale (comme la reconnaissance d'objets dans des images) et à le réentraîner sur de nouvelles données pour effectuer le même type de tâche, mais dans un domaine spécialisé.

3.3.2 Approches de l'apprentissage par transfert

L'apprentissage par transfert offre différentes approches pour exploiter les connaissances issues de modèles pré-entraînés et les appliquer à de nouvelles tâches. Voici quelques approches courantes :

Extraction de caractéristiques :

Les premières couches d'un modèle pré-entraîné servent d'extracteur de caractéristiques statiques, où leurs pondérations sont figées et non mises à jour. De nouvelles couches sont ajoutées par-dessus pour gérer la nouvelle tâche.

Ajustement fin (Fine-Tuning) :

Réentraînement partiel d'un modèle précédemment formé en mettant à jour les poids des couches sélectionnées (généralement les dernières) avec de nouvelles données de tâches, tout en préservant les poids des premières couches.

Apprentissage multitâche :

L'apprentissage multitâche utilise un modèle pré-entraîné pour exécuter simultanément plusieurs tâches connexes. Comme un modèle de diagnostic médical qui prédit : le type de maladie et la localisation de l'organe affecté.

3.4 Architecture du CNN

L'architecture CNN se compose de plusieurs couches en cascade qui extraient des fonctionnalités et classent les données. Le processus commence par la couche d'entrée, qui reçoit des données brutes, telles que des images. Les données passent ensuite par des couches convolutives qui appliquent des filtres (noyaux) pour extraire des caractéristiques locales de l'image. Ceci est suivi par des couches d'activation, telles que la fonction ReLU, qui ajoutent de la non-linéarité au modèle. Les couches de pooling sont ensuite utilisées pour réduire la dimensionnalité des données tout en préservant les informations sous-jacentes, en réduisant le nombre de paramètres et en augmentant l'efficacité du modèle. Dans les étapes finales, des couches entièrement connectées sont utilisées pour regrouper les fonctionnalités et prendre la décision finale, et la fonction Softmax est utilisée dans la couche de sortie pour déterminer la classe finale de l'image.

Cette architecture permet au modèle d'apprendre automatiquement les caractéristiques des données, ce qui le rend efficace dans les tâches de classification d'images et de reconnaissance de formes. [40]

3.4.1 Couche de Convolution

la base structurelle d'un CNN, où les opérations de convolution sont appliquées à l'aide de noyaux entraînés pour détecter les caractéristiques spatiales dans les images. Ces couches peuvent capturer des informations de position sensibles au contexte, créant ainsi des représentations visuelles. [41]

3.4.1.1 Fonction d'activation

appliquée pour convertir les signaux linéaires générés par convolution en représentations non linéaires, permettant au modèle d'apprendre à partir de modèles complexes. Les technologies telles que ReLU sont couramment utilisées en raison de leur capacité à réduire les problèmes de disparition de gradient. [41]

3.4.2 Mise en commun maximale :MaxPooling

utilisée pour réduire la dimension spatiale des cartes de caractéristiques et réduire le nombre de paramètres, sans perdre les informations sous-jacentes. Par exemple, MaxPooling permet d'améliorer l'insensibilité aux changements de position mineurs dans l'image. [41]

3.4.3 Entièrement connecté :Fully Connected

connecte chaque élément de la couche précédente à tous les neurones qu'elle contient, conduisant à la décision finale. Cette couche est chargée de combiner les représentations extraites des couches précédentes pour générer la sortie finale. [41]

La figure suivante 3.2 illustre tout ce qui précède.

3.5 Sous-modèles CNN

Pour améliorer la détection automatique des caractéristiques liées à l'autisme à partir d'images faciales, ce travail s'appuie sur plusieurs architectures avancées de réseaux neuronaux convolutifs, notamment :




FIGURE 3.2 – Schéma fonctionnel de l'architecture de base du réseau neuronal convolutif (CNN).

3.5.1 ResNet50V2

Il s'agit d'une version améliorée de ResNet50 (Residual Network) développée par Microsoft. ResNet aborde le problème de la disparition des gradients dans les réseaux très profonds en introduisant des « connexions de raccourci » ou des « connexions de saut » qui permettent aux gradients de circuler directement vers les couches précédentes. ResNet50V2 ajoute des améliorations à l'ordre de normalisation des lots et aux fonctions d'activation par rapport au ResNet50 d'origine. [42]

3.5.2 InceptionV3

'Inception version 3' il s'agit d'une version améliorée de la famille de modèles Inception développée par Google. Il dispose d'une architecture modulaire qui utilise des « unités d'inception » pour effectuer des opérations convolutives parallèles avec différentes tailles de noyau au sein de la même unité. Cela permet au modèle de capturer efficacement des fonctionnalités à différents endroits. Les améliorations apportées à InceptionV3 incluent l'utilisation de convolutions factorisées pour réduire le nombre

de paramètres et accélérer la formation. [43]

3.5.3 VGG16

'Groupe de géométrie visuelle' il s'agit d'un modèle CNN développé par le Visual Geometry Group (VGG) de l'Université d'Oxford. Il présente une architecture homogène qui se concentre sur l'augmentation de la profondeur du réseau. Ces architectures utilisent de très petites couches convolutives avec une taille de noyau 3x3 sur tout le réseau, avec la fonction d'activation ReLU appliquée après chaque couche convolutive. La principale différence entre les différentes configurations VGG, telles que VGG16 et VGG19, réside dans le nombre de couches convolutives, ce qui donne lieu à des réseaux plus profonds et plus complexes. [44]

3.5.4 DenseNet121

Il s'agit d'un modèle d'apprentissage profond composé de 121 couches disposées en blocs denses, chacun composé d'un nombre spécifique de couches. L'entrée du réseau est une image de 224 x 224 pixels. De plus, il inclut des couches de transition permettant de réduire la taille de la carte des caractéristiques, rendant DenseNet121 efficace pour la reconnaissance d'images. [39]

3.6 Conclusion

Enfin, ce chapitre fournit une présentation détaillée de la contribution technique proposée dans ce travail, où un système basé sur des réseaux neuronaux convolutifs a été construit pour extraire des caractéristiques d'images de visage et les utiliser dans un processus de classification efficace visant à détecter l'autisme. Nous avons sélectionné des modèles puissants et bien étudiés comme ResNet50V2, InceptionV3, DenseNet121

et VGG16. Les composants de base du réseau et leurs rôles ont également été expliqués. Cette contribution constitue la base qui sera testée pratiquement dans le prochain chapitre, en appliquant le modèle à des données réelles et en analysant les résultats obtenus.

Chapitre 4

Implémentation et Évaluation

4.1 Introduction

Dans ce chapitre, nous passons de la conception théorique à l'expérimentation concrète. À travers une série d'étapes structurées, nous mettons en œuvre notre travail de détection de l'autisme à l'aide d'outils de programmation avancés, du traitement initial des données à l'interprétation des résultats obtenus. Enfin, une discussion comparative est menée pour déterminer la performance de notre expérience par rapport à certaines études similaires antérieures.

4.2 Cadre de développement

Avant de commencer toute expérience ou mise en œuvre technique, il est nécessaire de placer le projet dans un environnement de travail organisé. Ce cadre de développement combine des choix concernant la programmation, la plateforme utilisée et la manière dont le projet est organisé. Il constitue la base sur laquelle reposent toutes les étapes ultérieures, facilitant ainsi la gestion du projet.

4.2.1 Le langage de programmation utilisé(Python)

Python est un langage de programmation de haut niveau, orienté objet et à usage général développé par Guido van Rossum en 1989 et officiellement publié en 1991. Sa syntaxe simple et sa lisibilité en font l'un des langages de programmation les plus populaires dans des domaines tels que l'analyse de données, l'intelligence artificielle, l'apprentissage automatique et la programmation scientifique. Python prend en charge la programmation structurée et orientée objet, est gratuit et open source et fonctionne sur divers systèmes d'exploitation tels que Windows, Linux et macOS, ce qui en fait un choix idéal pour les débutants comme pour les professionnels. [45]




FIGURE 4.1 – Logo Python.

4.2.1.1 Les Bibliothèques

KaggleHub : Une bibliothèque utilisée pour charger facilement des ensembles de données de Kaggle directement dans votre environnement de programmation.

TensorFlow : Il s'agit d'un framework open source développé par Google, utilisé pour développer des modèles d'intelligence artificielle, notamment d'apprentissage profond. Il est flexible et prend en charge l'exécution sur les CPU et les GPU et est utilisé dans les applications qui nécessitent un traitement de données massif ou un apprentissage à grande échelle. TensorFlow permet de construire des modèles à l'aide de graphiques de calcul.

Keras : Il s'agit d'une API de haut niveau utilisée pour créer et former des réseaux neuronaux facilement et rapidement. Keras était autrefois une bibliothèque autonome, mais fait désormais officiellement partie de TensorFlow et est accessible sur `tensorflow.keras`. Keras fournit des interfaces simplifiées pour la création de modèles et inclut des bibliothèques prêtes à l'emploi telles que ResNet, VGG et Inception via `keras.applications`.

scikitlearn : Une bibliothèque spécialisée dans l'analyse des résultats de modèles, comme le calcul de la matrice de précision et de confusion et la génération de rapports de classification.

NumPy : Une bibliothèque puissante pour le traitement des données numériques et matricielles, utilisée pour l'agrégation et le formatage des données.

os : Une bibliothèque intégrée en Python utilisée pour gérer les fichiers, tels que : spécifier les chemins, Créer des dossiers, parcourir le contenu des dossiers

shutil : Une bibliothèque intégrée est également utilisée pour effectuer des opérations avancées sur les fichiers et les dossiers, telles que : déplacer des fichiers, copier des fichiers, supprimer des répertoires.

PIL (Pillow) : Une bibliothèque pour travailler avec des images : les ouvrir, les modifier ou examiner leurs propriétés.

matplotlib.pyplot : Utilisé pour tracer des graphiques tels que l'évolution de la précision et de la perte pendant l'entraînement ou la courbe ROC.

4.2.2 Plateforme (Google Colab)

Google Colaboratory (Colab) est un environnement de programmation gratuit basé sur le cloud de Google Research, basé sur Jupyter Notebook et prenant en charge des langages tels que Python et R. Principalement utilisé dans l'intelligence artificielle, l'apprentissage automatique et l'analyse de données. Il offre un accès gratuit aux GPU

et aux unités de traitement des tenseurs (TPU), ce qui en fait un outil idéal pour exécuter des modèles de calcul lourds sans avoir besoin d’une infrastructure locale. Colab prend en charge l’intégration avec Google Drive et GitHub, permettant un partage collaboratif en temps réel, améliorant le travail d’équipe sur des projets de recherche ou éducatifs. [46]



FIGURE 4.2 – Logo colab.

4.3 Approche de classification d’images faciales pour le TSA

Nous allons maintenant présenter l’approche systématique utilisée pour détecter les troubles du spectre autistique (TSA) à partir d’images faciales. L’objectif est de construire un système intelligent capable d’analyser les visages des enfants pour distinguer ceux qui présentent des signes d’autisme de ceux qui n’en présentent pas. Cette approche repose sur plusieurs étapes principales, qui sont :

4.3.1 Présentation des bases de données utilisées

Dans ce travail, deux bases de données d’images faciales ont été utilisées pour former et évaluer un modèle de détection des troubles du spectre autistique (TSA), à savoir :

4.3.1.1 Ensemble de données 1 : Données sur les visages autistes (Autism Image Data/Kaggle)

La base de données utilisée, intitulée 'Autism Image Data', est une collection d'images faciales hébergée sur la plateforme Kaggle, mise à disposition par l'utilisateur cihan063. Elle est spécifiquement conçue pour l'entraînement de modèles de classification dans le but de détecter les signes de trouble du spectre de l'autisme (TSA) à partir des images d'enfants.

-Cette base de données contient un total de 5880 images réparties dans quatre sous-ensembles principaux :

Train : 2540 images

Test : 300 images

Validation : 100 images (50 Autistic, 50 Non Autistic)

Consolidated : 2940 images (1470 Autistic, 1470 Non Autistic)

-Les images sont étiquetées selon deux classes principales :

Autistic (enfants atteints de TSA) NonAutistic (enfants neurotypiques)

-Caractéristiques de la base de données :

Type de données : images faciales RGB (format .jpg).

-Objectif : permettre l'entraînement, la validation et le test de modèles de deep learning pour la classification binaire (autiste / non autiste).

-C'est une base largement utilisée dans des études récentes (Yolcu et al., 2023 ; Alkahtani et al., 2023), ce qui en fait un choix pertinent pour des comparaisons reproductibles. [47]

4.3.1.2 Ensemble de données 2 : Données sur les visages autistes (YTUIA-2D/Kaggle)

La deuxième base de données exploitée dans ce projet de recherche est intitulée YTUIA-2D, proposée par l'Université Islamique Internationale de Malaisie (UIAM / IIUM). Elle a été construite à partir d'un total de 100 vidéos YouTube, dont :

- 50 vidéos issues du Self-Stimulatory Behaviours Dataset (SSBD) — un référentiel reconnu sur les comportements liés à l'autisme.

- 50 vidéos supplémentaires obtenues auprès de thérapeutes ou d'institutions spécialisées.

Les vidéos de contrôle (normales) ont été choisies parmi des activités scolaires d'enfants d'âge préscolaire sur YouTube, respectant la même catégorie d'âge.

-Détails sur les participants :

Groupe ASD (Trouble du Spectre de l'Autisme) :

- 123 enfants : 93 garçons et 30 filles

- Âge : de 3 à 11 ans

-Groupe Contrôle (Neurotypiques) :

- 173 enfants : 117 garçons et 56 filles

- Âge : de 1 à 11 ans

Méthodologie de traitement des vidéos :

Détection faciale appliquée à chaque image extraite via l'algorithme MTCNN.

Répartition des données :

- Ensemble d'entraînement : 1068 images

- Ensemble de test : 100 images

Forces de cette base de données :

- Source vidéo riche et diversifiée

- Démarche rigoureuse de nettoyage et d'homogénéisation [48]

- La fonction de base qui charge l'ensemble de données depuis Kaggle : kaggle-

hub.datasetdownload()

4.3.2 Prétraitement des données

Le prétraitement constitue une étape cruciale dans tout projet d'apprentissage profond, en particulier lorsqu'il s'agit d'images faciales sensibles comme celles utilisées pour la détection précoce du trouble du spectre autistique (TSA). L'objectif principal de cette étape est d'assurer une qualité, une homogénéité et une pertinence maximales des données fournies au modèle d'apprentissage. Cette phase comprend généralement plusieurs opérations telles que :

- L'alignement et le recadrage pour centrer l'attention sur les traits faciaux pertinents,
- Le redimensionnement des images pour les adapter à l'entrée du modèle,
- La normalisation des pixels, permettant une meilleure convergence du réseau de neurones.

L'objectif global est d'assurer une homogénéité et une cohérence des données afin d'optimiser les performances du modèle lors de l'entraînement

Dans notre cas : les deux bases de données ont suivi prétraitement distinctes. La deuxième s'est appuyée sur un redimensionnement simple et une normalisation des images, sans augmentation de données, ce qui en fait une configuration classique. En revanche, La première base intègre une stratégie avancée d'augmentation des données (data augmentation) pour améliorer la robustesse du modèle. De plus, le découpage 80/20 des données y a été effectué par code, assurant un contrôle direct sur la répartition des classes. Cette complémentarité renforce la validité expérimentale de l'approche adoptée. Le tableau 4.1 illustre les bases de ce traitement.

TABLE 4.1 – Comparaison des prétraitements des deux bases de données

Aspect	Base de données 1 (Autism Image Data)	Base de données 2 (YTUIA_2D)
Modèles utilisés	DenseNet121	ResNet50V2, InceptionV3, VGG16
Taille des images	224×224 pour toutes	ResNet/VGG16 : 224×224 InceptionV3 : 299×299
Normalisation	rescale=1./255	rescale=1./255
Augmentation des données	Appliquée (flip, rotation, zoom, etc.)	Non appliquée
Chargement des images	<code>flow_from_directory()</code> , <code>class_mode='categorical'</code>	<code>flow_from_directory()</code> , <code>class_mode='binary'</code>
Découpage des données	Découpage programmé (80% / 20%) avec validation interne	Dossiers déjà séparés en Train/Test
Batch size	32	32
Problème de classification	Classification binaire (Autistic vs Non-Autistic)	Classification binaire (Autistic vs Non-Autistic)

4.3.3 Extraction des caractéristiques

Les CNN tels qu’Inception, VGG16, ResNet50 et Densnet121 extraient et isolent les caractéristiques profondes des images, permettant au modèle d’apprentissage de différencier efficacement les catégories autistiques et non autistiques. Ces modèles, pré-entraînés sur ImageNet, sont adaptés par apprentissage par transfert, et leurs couches entièrement connectées sont optimisées pour améliorer les performances.

4.3.4 Choix du modèle de classification

L'extraction des caractéristiques consiste à identifier et à isoler les éléments visuels les plus répandus dans les images. Pour la tâche de classification binaire (autiste/non-autiste), un réseau neuronal convolutif (CNN) a été utilisé. Cette architecture est particulièrement adaptée à l'analyse d'images faciales. Le tableau 4.2 présente les caractéristiques les plus importantes utilisées dans la sélection des modèles.

TABLE 4.2 – Comparaison des modèles utilisés pour l'extraction de caractéristiques

Modèle	Nombre de couches	Taille du modèle	Capacité d'extraction de caractéristiques	Raison du choix
VGG16	16	Environ 528 Mo	Capture efficacement les caractéristiques de bas et moyen niveau	Architecture simple, stable et facile à adapter
DenseNet	121	32 Mo	Excellente capture de fonctionnalités grâce à des connexions denses qui réutilisent les fonctionnalités.	Plus grande profondeur, utile pour des images complexes
ResNet50V2	50	Environ 98 Mo	Traite des images complexes sans perte d'information	Les connexions résiduelles évitent le problème de dégradation du gradient
InceptionV3	Environ 48	Environ 92 Mo	Bon équilibre entre vitesse et précision, multi-échelle	Efficace pour différents types d'images, très optimisé

4.3.5 Prise de décision et prédiction

La prise de décision est l'étape finale du processus de classification dans notre système de détection des troubles du spectre autistique (TSA). Une fois qu'un modèle CNN est formé pour distinguer les visages des enfants autistes et non autistes, il devient

capable de prédire à quelle catégorie appartient une nouvelle image invisible.

Dans notre recherche, prendre cette décision permet de soutenir le diagnostic initial ou le dépistage automatisé, en particulier dans les endroits où l'accès aux spécialistes est limité. L'efficacité de cette étape dépend en grande partie de la qualité du modèle, de l'équilibre des données et des performances obtenues lors des tests.

4.4 Métriques d'évaluation du modèle

Avant de présenter les résultats expérimentaux obtenus, il est important de mentionner quelques termes de base utilisés. :

- **True Positives (TP)** : ou vrais positifs cas que le modèle a correctement prédit comme étant « autistes », ce qui est le cas.
- **False Positives (FP)** : ou Faux Positifs cas que le modèle a prédit comme « autistes » mais qui sont en réalité « non autistes ».
- **True Negatives (TN)** : ou Vrais négatifs cas que le modèle a correctement prédit comme étant « non autistes », ce qui est le cas.
- **False Negatives (FN)** : ou Faux négatifs cas que le modèle prédisait comme « non autistes » mais qui sont en réalité « autistes ».

Ces quatre mesures permettent ensuite de calculer d'autres métriques essentielles telles que la précision (Precision), le rappel (Recall), et le score F1.

4.4.1 Analyse de la courbe d'apprentissage précision et perte (Accuracy and Loss)


Pour évaluer la performance d'apprentissage de nos modèles CNN, nous avons analysé les courbes d'entraînement et de validation (accuracy et loss) générées pour chaque

base de données. Ces courbes permettent de visualiser la manière dont le modèle apprend au fil des époques, et d'identifier d'éventuels cas de surapprentissage (overfitting) ou de sous-apprentissage (underfitting).


Une courbe d'accuracy montre la proportion de prédictions correctes tandis qu'une courbe de loss mesure l'erreur du modèle. En général :

- Une courbe d'accuracy croissante indique un bon apprentissage.
- Une courbe de loss décroissante est également un bon signe.
- Une divergence entre les courbes d'entraînement et de validation signale un overfitting.


Les figures suivantes présentent les courbes d'apprentissage obtenues pour les deux bases de données utilisés.




(a) Précision(Accuracy) - BDD 1



(b) Perte(Loss) - BDD 1



(c) Précision(Accuracy) - BDD 2




(d) Perte(Loss) - BDD 2

FIGURE 4.3 – Courbes d'apprentissage (Précision et Perte) pour les deux jeux de données.

4.4.2 Matrice de confusion

Les matrices de confusion permettent d'évaluer la performance des modèles de classification en détaillant les cas de bonne et mauvaise classification selon les étiquettes réelles et prédites.



(a) Matrice de confusion – BDD 1

(b) Matrice de confusion – BDD 2

FIGURE 4.4 – Matrice de confusion pour les deux ensembles de données utilisés.

Matrice 1 :

- **True Positives (TP)** = 257 : cas correctement identifiés comme autistes.
- **False Negatives (FN)** = 37 : cas autistes incorrectement classés comme non autistes.
- **False Positives (FP)** = 58 : cas non autistes incorrectement classés comme autistes.
- **True Negatives (TN)** = 236 : cas non autistes correctement classés.

Matrice 2 :

- **True Positives (TP)** = 47 : Les cas d'enfants autistes ont été correctement classés.
- **False Negatives (FN)** = 2 : Cas d'enfants autistes classés comme non affectés.
- **False Positives (FP)** = 6 : Cas d'enfants non infectés qui ont été classés comme infectés.
- **True Negatives (TN)** = 44 : Cas d'enfants non infectés correctement classés.

4.4.3 Courbe de ROC(Receiver Operating Characteristic)

Pour évaluer les performances du modèle de classification binaire, nous avons tracé une courbe caractéristique de fonctionnement du récepteur (ROC), qui relie le taux de vrais positifs (TP) au taux de faux positifs (FP) pour différents seuils de classification.

4.4.4 Analyse des courbes ROC

L'évaluation des performances de classification a été réalisée à l'aide des courbes ROC (Receiver Operating Characteristic), qui illustrent la relation entre le taux de vrais positifs (TPR) et le taux de faux positifs (FPR).

— Base de données 1 – Autism Image Data

La courbe ROC associée au modèle DenseNet121 atteint une surface sous la courbe (AUC) de 0,92, ce qui indique une bonne capacité de distinction entre les images autistiques et non autistiques. Le modèle conserve un équilibre satisfaisant entre la sensibilité et la spécificité, même sans application d'augmentation de données.

— Base de données 2 – YTUIA_2D

La courbe ROC obtenue pour le modèle combiné (ResNet50V2, InceptionV3, VGG16) montre une AUC de 0,97, ce qui reflète une excellente performance. Ce résultat souligne la pertinence de l'approche basée sur la fusion de caractéristiques extraites par plusieurs architectures CNN.




FIGURE 4.5 – Courbe ROC – Base Autism Image Data




FIGURE 4.6 – Courbe ROC – Base YTUIA_2D

4.4.5 Indicateurs de performance de classification

Les indicateurs suivants nous permettent d'analyser la qualité des prédictions du modèle :

4.4.5.1 Précision(Precision)

Il exprime la capacité du modèle à réduire les erreurs dans la classification des cas positifs, ce qui reflète la fiabilité du modèle à distinguer correctement les classes. [34]

Formule de la Précision

$$\text{Précision (P)} = \frac{TP}{TP + FP} \times 100\%$$

4.4.5.2 Rappel(Recall)

Est une mesure qui exprime la capacité d'un modèle à détecter les vrais cas positifs parmi tous les cas positifs réels. [34]

Formule du Rappel

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\%$$

4.4.5.3 Score F1(F1-score)

Il s'agit de la moyenne harmonique entre la précision et le rappel, et elle est utilisée pour évaluer le pourcentage de résultats corrects parmi tous les résultats réels. [34]

Formule du Score F1

$$F\text{-Score} = \frac{2 \times \text{Précision} \times \text{Rappel}}{\text{Précision} + \text{Rappel}} \times 100\%$$

4.4.5.4 Effectif (Support)

Fait référence au nombre total d'observations dans chaque classe de l'ensemble de données. Il représente la fréquence des éléments dans une classe donnée et est utilisé pour calculer des mesures telles que la précision et le rappel.

4.4.6 Rapport de classification

— Ce tableau 4.3 présente le rapport de classification du premier modèle de base de données appliqué aux données sur l'autisme, mesurant les performances à l'aide de quatre indicateurs clés : précision, rappel, mesure F1 et nombre d'échantillons par classe. Une précision globale de 84 (pour cent) a été atteinte, démontrant une performance équilibrée entre les catégories « autiste » et « non autiste ».

TABLE 4.3 – Rapport de classification du BDD 1.

Classe	Précision	Rappel	F1-score	Support
Autistic	0.85	0.86	0.85	294
Non_Autistic	0.86	0.84	0.85	294
Exactitude (Accuracy)	0.85 (sur 588 échantillons)			
Moyenne macro	0.85	0.85	0.85	588
Moyenne pondérée	0.85	0.85	0.85	588

— Ce tableau 4.4 présente les mesures de performance du modèle sur un deuxième ensemble de données de 99 échantillons.

La classe 0 (par exemple, non autiste) a une précision de 0,89 et un rappel de 0,96.

La classe 1 (par exemple, l'autisme) montre une précision de 0,96 et un rappel de 0,88. Le modèle atteint une précision globale allant jusqu'à 92

TABLE 4.4 – Rapport de classification du BDD 2

Classe	Précision	Recall	F1-score	Support
0	0.89	0.96	0.92	49
1	0.96	0.88	0.92	50
Accuracy	0.92 (sur 99 échantillons)			
Macro Moyenne	0.92	0.92	0.92	99
Moyenne Pondérée	0.92	0.92	0.92	99

4.5 Études expérimentales sur les performances des modèles CNN

Dans ce tableau 4.5, nous présentons les résultats de certaines études expérimentales menées sur un groupe de réseaux neuronaux profonds (CNN) qui ont été testés sur deux ensembles de données différents d'images d'enfants avec et sans autisme. Le tableau montre la précision moyenne obtenue pour chaque modèle, ainsi qu'une brève analyse

des performances de chaque modèle et des suggestions de développement futur. Nous constatons que la combinaison de plusieurs modèles d'ensemble tels que InceptionV3, ResNet50V2 et VGG16 a donné le meilleur résultat de 92%, indiquant la puissance de cette approche dans l'amélioration des performances.

TABLE 4.5 – Résultats expérimentaux des tests de modèles CNN sur deux bases de données

Technique	Dataset	Résultat	Évaluation et recommandations
MobileNetV2	01	82%	Bon taux de précision, nécessite plus de données pour le problème de surapprentissage.
VGG19 (A)	01	83%	Très bon résultat, nécessite quelques ajustements pour améliorer la précision.
VGG19 (B)	01	84%	Même évaluation que le test (A), Avec une certaine amélioration des performances.
VGG16	01	78%	Bon résultat, plus de données peuvent améliorer les performances.
InceptionV3 + VGG19	01	83%	Bonne précision, avec une marge d'amélioration en optimisant davantage les paramètres.
DenseNet121	01	85%	Bonne précision, nécessite un réglage.
ResNet50V2	02	70%	Des performances correctes, qui peuvent être améliorées grâce à des techniques d'organisation et d'enrichissement des données.
InceptionV3	02	67%	Un résultat proche du bon, indiquant la nécessité de données plus diversifiées et équilibrées.
VGG16	02	55%	Faible précision, nécessite plus d'optimisation et un meilleur prétraitement.
InceptionV3 + ResNet50V2 + VGG16	02	92%	La combinaison des modèles a permis d'obtenir les meilleures performances globales, une approche qui mérite d'être explorée plus en profondeur.

4.6 Conclusion

Ce chapitre nous a permis de valider expérimentalement notre approche de détection de l'autisme à partir d'images faciales. Grâce à une méthodologie rigoureuse et à l'utilisation de modèles profonds performants, nous avons pu obtenir des résultats satisfaisants. L'évaluation du modèle sur deux ensembles de données distincts, ainsi que sa comparaison avec des travaux antérieurs, renforce la crédibilité de notre solution. Ces résultats fournissent une base solide pour envisager des améliorations futures.

Conclusion Générale

En conclusion, nous avons mis en évidence le grand potentiel des techniques d'apprentissage profond dans le domaine médical, notamment dans la détection précoce des troubles du spectre autistique. Les résultats obtenus à l'aide de modèles CNN pré-entraînés ont montré une bonne efficacité dans la classification des images entre les enfants autistes et non autistes, confirmant la faisabilité de l'IA comme outil d'aide aux décisions médicales ; ces résultats démontrent qu'avec le temps, l'IA pourrait atteindre un niveau d'avancement permettant l'élimination partielle ou complète de l'intervention humaine à certaines étapes du diagnostic, notamment dans les cas qui nécessitent rapidité et précision dans la prise de décision.

Dans le cadre des travaux futurs, nous aspirons à développer ce travail à travers plusieurs voies dont les plus importantes sont :

- Intégrer les bases de données actuellement utilisées dans une base de données unifiée, permettant une plus grande diversité d'échantillons et améliorant la capacité du modèle à généraliser.

- Fusion de fonctionnalités : combinaison de fonctionnalités extraites de chaque base de données pour créer une représentation unifiée et riche qui aide le modèle à apprendre à partir d'informations plus précises et plus diversifiées.

- S'appuyer sur des données multimodales, en combinant des images avec des informations comportementales ou cliniques telles que les antécédents médicaux et les tests psychologiques, peut améliorer considérablement les performances du modèle.

-Utilisation de techniques de prétraitement avancées pour standardiser la qualité de l'image et réduire le bruit.

-Élargir la portée de l'étude pilote pour inclure différents groupes d'âge et des origines sociales et culturelles diverses, afin d'améliorer l'exhaustivité des résultats.

-Développer un outil d'application destiné à la fois aux praticiens médicaux et à un usage personnel, permettant au modèle d'être facilement utilisé tout en respectant les considérations éthiques et de confidentialité.

Avec ces dimensions futuristes, nous espérons que cette recherche sera la première étape d'un long chemin d'innovation visant à améliorer le diagnostic précoce et le soutien aux personnes atteintes de troubles du spectre autistique.

Bibliographie

- [1] Wikipédia, “Maladie chronique.19-01-2025.”
- [2] Organisation mondiale de la Santé, “Maladies non transmissibles.16-10-2023.”
- [3] “« autisme ». consulté le 3 février 2025. [https://www.who.int/fr/news-room/questions-and-answers/item/autism-spectrum-disorders-\(asd\)..](https://www.who.int/fr/news-room/questions-and-answers/item/autism-spectrum-disorders-(asd)..)”
- [4] “Harvey, camille. « interventions avec le robot nao pour le développement des habiletés sociales d’un adolescent atteint d’un trouble du spectre de l’autisme (tsa) : étude de cas ». engd, université du québec à chicoutimi, 2024. <https://constellation.uqac.ca/id/eprint/9943/..>”
- [5] Institut Pasteur, “Autisme.” Fiche maladie du Centre Médical. 22-03-2019.
- [6] Institut Pasteur, “Autisme,” 2019. Consulté le 22 mars 2019.
- [7] D. J. Mustafa, *Al-Tawahhid (Autism)*. Noor Book, 2015. Original title in Arabic : .
- [8] J. Zeidan, E. Fombonne, J. Scora, A. Ibrahim, M. S. Durkin, S. Saxena, A. Yusuf, A. Shih, and M. Elsabbagh, “Global prevalence of autism : A systematic review update,” *Autism Research*, vol. 15, no. 5, pp. 778–790, 2022.
- [9] R. K. Al-Abbadi, *Al-Tawahhud [Autism]*. Noor Book, 2017.
- [10] Autism Speaks, “What causes autism?.” Consulté le 5 février 2025.
- [11] K. Yenkovyan, M. Mkhitarian, and G. Bjørklund, “Environmental risk factors in autism spectrum disorder : ANarrative review,” vol. 31, no. 17, pp. 2345–2360.

- [12] A. S. Belaid, *L'effet d'un programme moteur basé sur des jeux réduits sur l'interaction sociale des enfants autistes*. PhD thesis, Université d'Alger, Faculté des Sciences Civiles et Sportives, 2023.
- [13] D. Polton, "Les données de santé," vol. 34, no. 5, pp. 449–455.
- [14] J. Ferreira, "Demographic data," in *Encyclopedia of Big Data* (L. A. Schintler and C. L. McNeely, eds.), Living Edition, pp. 1–4, Cham : Springer International Publishing, 1 ed., 2017.
- [15] National Cancer Institute, "Clinical data." Accessed : February 8, 2025.
- [16] Wikimédica, "Donnée clinique." Consulté le 8 février 2025.
- [17] D. Magnani, D. Negra, and D. Fabre Bou Abboud, "Dossier documentaire imagerie médicale," 04 2018. Documentation médicale sur l'imagerie diagnostique.
- [18] Wikipédia, "Imagerie médicale. 17-12-2024."
- [19] Center for Devices and Radiological Health, "What is digital health ?.12-05-2024."
- [20] V. Brusic, J. S. Wilkins, C. A. Stanyon, and J. Zeleznikow, "Data learning : Understanding Biological data,"
- [21] Wikipédia, "Base de données biologiques."
- [22] PharmacoMédicale, "Fiches de lca en pharmacoépidémiologie." Ressource pédagogique en ligne. Consulté le 15 février 2025.
- [23] M. Ghosh and A. Thirugnanam, "Introduction to artificial intelligence," in *Artificial Intelligence for Information Management : A Healthcare Perspective* (K. G. Srinivasa, S. G. M., and S. R. M. Sekhar, eds.), pp. 23–44, Springer.
- [24] "IDS120 - Étude de la proposition de règlement européen pour l'intelligence artificielle dans le secteur de la santé." Section : 2021-2022.
- [25] N. Nasri and O. Aguech, "Développement et évaluation d'une formation en ligne sur l'intégration de l'intelligence artificielle dans l'enseignement,"

- [26] E. H. Moustaid and Y. Moflih, “L’impact de l’introduction de l’intelligence artificielle sur le marché du travail,” vol. 5, no. 7. Number : 7.
- [27] L. D. Matteis, “Introduction à l’apprentissage,”
- [28] H. Olou, “Intelligence artificielle et ses domaines d’applications,”
- [29] Talend, “Big data et intelligence artificielle : enjeux business.” Ressource en ligne.
- [30] B. H. Eddine and B. Aya, “La classification des maladies via une analyse médicale basée sur l’apprentissage profond,”
- [31] I. Saadi and Z. Bordji, “Revue systématique de la littérature sur les méthodes d’apprentissage automatique pour l’analyse des big data avec une Étude de cas,” mémoire de master, Université Mohamed El-Bachir El-Ibrahimi de Bordj Bou Arreridj, Bordj Bou Arreridj, Algérie, 2024.
- [32] R. Praba, G. Darshan, K. T. Roshanraj, and B. S. Prakash, “Study on machine learning algorithms,” *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, vol. 7, pp. 67–72, 7 2021.
- [33] R. Kenge, “Machine learning, its limitations, and solutions over IT,” *International Journal of Applied Research on Information Technology and Computing*, vol. 11, no. 2, p. 73, 2020.
- [34] S. Merdji and S. Rebiai, “Prédiction des tumeurs cérébrales dans les images IRM par l’apprentissage profond,” mémoire de master, Université Mohamed El-Bachir El-Ibrahimi de Bordj Bou Arreridj, Bordj Bou Arreridj, Algérie, 2024.
- [35] M. P. Talabard, A. Bordner, and A. Feydy, “L’intelligence artificielle au service de l’imagerie de la spondyloarthrite : présent et futur,” *Revue du Rhumatisme*, 1 2025.

- [36] C. M. Lontchi, “Contribution à la prédiction des pertes de puissance sur un réseau électrique par un modèle à base de réseau de neurones,” mémoire de maîtrise, Université du Québec à Montréal, Montréal, Canada, 2021.
- [37] M. S. Qureshi, M. B. Qureshi, J. Asghar, F. Alam, and A. Aljarbough, “[retracted] prediction and analysis of autism spectrum disorder using machine learning techniques,” vol. 2023, no. 1, p. 4853800. _eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1155/2023/4853800>.
- [38] I. Ahmad, J. Rashid, M. Faheem, A. Akram, N. A. Khan, and R. U. Amin, “Autism spectrum disorder detection using facial images : A performance comparison of pretrained convolutional neural networks,” vol. 11, no. 4, pp. 227–239.
- [39] B. Khan, S. M. Bhatti, and A. Akram, “Autism spectrum disorder detection in children via deep learning models based on facial images,” vol. 13, no. 1.
- [40] P. Sharma, “Introduction to convolutional neural networks in deep learning,2022-03-01,<https://www.analyticsvidhya.com/blog/2022/03/basic-introduction-to-convolutional-neural-network-in-deep-learning/>.”
- [41] X. Zhao, L. Wang, Y. Zhang, X. Han, M. Deveci, and M. Parmar, “A review of convolutional neural networks in computer vision,” vol. 57, no. 4, p. 99.
- [42] K. He, X. Zhang, S. Ren, and J. Sun, “Identity mappings in deep residual networks.”
- [43] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the inception architecture for computer vision.”
- [44] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition.”
- [45] P. Fuchs and P. Poulain, “Cours de python : Introduction à la programmation python pour la biologie.”

- [46] “Google colab. <https://colab.research.google.com/>.”
- [47] “Autism_image_data.<https://www.kaggle.com/datasets/cihan063/autism-image-data..>”
- [48] “YTUIA-2d.<https://www.kaggle.com/datasets/sadikibrahim17/ytuia-2d..>”