

Faculté des Sciences Exactes et d'Informatique
Département de Mathématiques et informatique
Filière : Informatique

RAPPORT DE PROJET DE MASTER EN INFORMATIQUE
Option : Ingénierie des Systèmes d'Information

THEME :

**Prédiction de la Maladie de Parkinson à
l'Aide du Réseau de Neurones Artificiels**

Etudiant(e) : BENZIDANE Mohamed

BENDAHMANE Thamine

Encadrant(e) : Fatiha DJAHAFI

Année Universitaire 2022-2023

Résumé

La maladie de Parkinson (MP) est une maladie chronique et dégénérative qui affecte principalement le système nerveux central, en particulier les régions du cerveau impliquées dans le contrôle du mouvement et de l'équilibre, provoquant des symptômes tels que des tremblements, une rigidité musculaire, des mouvements lents et des difficultés à marcher. Le diagnostic précoce de cette maladie (MP) est difficile en raison du développement progressif des symptômes, ce qui rend difficile l'identification de la maladie à un stade précoce. Les techniques d'apprentissage automatique, comme les réseaux de neurones artificiels (RNA), sont capables d'apprendre des schémas complexes dans les données d'entrée et de prédire des résultats avec une précision élevée.

Dans le cadre de cette étude, nous présentons une approche hybride où nous combinons les réseaux de neurones artificiels avec l'algorithme d'optimisation de Baleine (WOA) pour développer un modèle robuste et précis visant à prédire l'apparition de la MP. Grâce à cette approche hybride, notre objectif est de renforcer la précision du diagnostic de la MP et d'améliorer la gestion des symptômes chez les patients atteints de cette maladie.

Mots-clés : maladie de Parkinson, réseaux de neurones artificiels, prédiction, apprentissage automatique, algorithme d'optimisation de baleine.

Abstract

Parkinson's disease (PD) is a chronic and degenerative condition that primarily affects the central nervous system, particularly the regions of the brain involved in the control of movement and balance, leading to symptoms such as tremors, muscle rigidity, slow movements, and difficulty walking. Early diagnosis of this disease (PD) is challenging due to the gradual development of symptoms, making it difficult to identify the disease at an early stage. Machine learning techniques, such as artificial neural networks (ANNs), are capable of learning complex patterns in input data and predicting outcomes with high accuracy.

In the context of this study, we introduce a hybrid approach where we combine artificial neural networks with the Whale Optimization Algorithm (WOA) to develop a robust and precise model aimed at predicting the onset of PD. Through this hybrid approach, our goal is to enhance the accuracy of PD diagnosis and improve symptom management in patients with this disease.

Keywords: Parkinson disease, artificial neural networks, prediction, machine learning, whale optimization algorithm.

Liste des figures

Figure N°	Titre de la figure	Page
Figure 1	Le neurone biologique.	19
Figure 2	Schéma de Fonctionnement d'un Neurone Artificiel	20
Figure 3	Mise en correspondance neurone biologique / neurone artificiel	21
Figure 4	Fonction ReLU	22
Figure 5	Fonction sigmoïde	23
Figure 6	Fonction softmax	23
Figure 7	Fonction tanh	24
Figure 8	Algorithme de Recherche de Baleines	30
Figure 9	Organigramme de l'optimisation de la recherche de baleines travaillant sur MLP	34
Figure 10	La page d'accueil	44
Figure 11	Description de MP	44
Figure 12	Distribution des données	45
Figure 13	Fenêtre de l'approche	45
Figure 14	Fenêtre d'exécution de la recherche WOA	46
Figure 15	Évaluation du modèle	46
Figure 16	Résultat de classification	47

Liste des tableaux

Tableau N°	Titre du tableau	Page
Tableau 1	Tableau comparatif des stratégies de détection précoce de la maladie de Parkinson basées sur les techniques d'apprentissage machine	15
Tableau 2	Tableau représentant les Paramètres de notre approche	38
Tableaux 3	Tableau représentant les indices de performance des modèles pour l'ensemble des 10 modèles	42

Liste des abréviations

Abréviation	Expression Complète
MP	La maladie de Parkinson
RNA	Réseau de neurones artificiels
WOA	Whale Optimization Algorithm
MLP	Multilayer perceptron
AM	Apprentissage machine
SVM	Les machines à vecteurs de support
ELM	Extreme Learning Machine (La machine d'apprentissage extrême)
GA	Genetic Algorithm (Les algorithmes génétiques)
WK	Wavelet kernel
OPF	Optimum-Path-Forest
OCFA	Optimized-CuttleFish-Algorithm
K-PPV	K-Plus Proche Voisins
NB	Naïve Bayésienne
RNP	Réseau Neuronal Probabiliste
ACP	Analyse en Composantes Principales
PPE	Pitch Period Entropy
PML	Perceptron Multicouche
FBR	Fonction de Base Radiale

Table des matières

Introduction Générale	3
Chapitre 1 Généralité sur la Classification Automatique	5
1.1 Introduction	5
1.2 Apprentissage Machine	5
1.2.1 Définition	5
1.2.2 Exemples d'utilisation	6
1.2.3 Les Algorithmes.....	7
1.3 Etat de l'art.....	9
1.4 Comparaison.....	14
1.5 Conclusion.....	16
Chapitre 2 Réseaux de Neurones Artificiels.....	17
2.1 Introduction	17
2.2 Historique	17
2.3 Le neurone biologique.....	18
2.4 Le Neurone Artificiel	19
2.4.1 Définition	19
2.4.2 Le lien entre les neurones biologiques et neurones artificiels	20
2.5 Fonction d'activation.....	22
2.5.1 Fonction ReLU.....	22
2.5.2 Fonction Sigmoidé	22
2.5.3 Fonction SoftMax	23
2.5.4 Fonction Tangente Hyperbolique	24
2.6 Les différents types de Réseaux de Neurones Artificiels.....	24
2.6.1 Réseau de neurones FeedForward	24
2.6.2 Réseau de neurones récurrents.....	25
2.6.3 Réseau de neurones convolutifs.....	25

2.6.4	Réseau de neurones profonds.....	25
2.7	Les applications des réseaux de neurones artificiels.....	25
2.8	Les Travaux des réseaux de neurones artificiels sur la maladie de Parkinson.....	26
2.9	Conclusion.....	28
Chapitre 3 Approche Proposée		29
3.1	Introduction	29
3.2	Algorithme de Recherche de Baleines	30
3.2.1	Pseudo-code	31
3.3	Perceptron multicouche.....	31
3.4	Optimisation de MLP avec l’algorithme de recherche de Baleines	33
3.4.1	Pseudo-code	35
Chapitre 4 Implémentation , Résultats et Discussion		37
4.1	Introduction	37
4.2	Description de jeux de données utilisé.....	37
4.3	Chargement et prétraitement des données.....	38
4.4	Recherche et formation d'architecture de modèle	38
4.5	Environnement de développement.....	39
4.6	Évaluation du modèle.....	39
4.7	Résultats du modèle proposé.....	41
4.8	Comparaison avec d’autres modèles	41
4.9	Discussion	43
4.10	Les fenêtres de l'application Web.....	44
4.11	Implications cliniques.....	47
4.12	Conclusion	48
Conclusion Générale.....		49
Bibliographie.....		50

Introduction Générale

La maladie de Parkinson (MP) représente un défi majeur en neurologie, en raison de son caractère chronique et dégénératif. Cette pathologie cible principalement le système nerveux central, plus spécifiquement les régions du cerveau responsables du contrôle du mouvement et de l'équilibre. Les symptômes qui en résultent, tels que les tremblements, la rigidité musculaire, les mouvements lents et les difficultés à marcher, impactent considérablement la qualité de vie des individus atteints de cette maladie.

L'une des difficultés majeures associées à la maladie de Parkinson réside dans le diagnostic précoce. Les symptômes se développent progressivement, ce qui rend ardue la détection de la maladie à un stade précoce. Cela pose un véritable défi pour les professionnels de la santé, car un diagnostic tardif peut entraîner un retard dans la prise en charge et la gestion des symptômes, limitant ainsi les options de traitement.

Cependant, ces défis trouvent une lueur d'espoir dans le domaine de l'apprentissage automatique. Les techniques d'apprentissage machine, en particulier les réseaux de neurones artificiels (RNA), ont démontré leur capacité à décrypter des schémas complexes dans les données d'entrée et à effectuer des prédictions avec une précision remarquable.

Cette étude présente une approche hybride en associant les réseaux de neurones artificiels à l'algorithme d'optimisation de Baleine (WOA) dans le but de créer un modèle précis pour la prédiction de la maladie de Parkinson.

Ce mémoire se compose en quatre chapitres, avec une introduction et une conclusion générale :

- Dans le premier chapitre, nous présentons une introduction à l'apprentissage machine, en détaillant ses algorithmes et ses différentes applications. Nous passons également en revue les travaux antérieurs qui ont exploré l'utilisation de l'apprentissage automatique pour prédire la maladie de Parkinson.
- Dans le deuxième chapitre, nous approfondissons la discussion sur les réseaux de neurones artificiels, en abordant leur histoire, les similitudes avec les neurones biologiques, les fonctions d'activation et leurs diverses applications, y compris leur utilisation dans la recherche sur la maladie de Parkinson.
- Le troisième chapitre présente l'approche proposée. Il commence par une introduction puis présente l'algorithme d'optimisation des baleines (Whale Optimization Algorithm ou WOA) et son pseudo-code. Le chapitre traite également du perceptron multicouche (MLP) et de la manière dont il peut être optimisé à l'aide de l'algorithme WOA. En outre, il fournit une description de l'ensemble de données sur la maladie de Parkinson utilisé dans l'étude.
- Le quatrième chapitre se concentre sur la présentation des résultats, les comparaisons et les discussions. Il commence par une introduction et présente ensuite les résultats du modèle proposé. Le chapitre compare ces résultats avec d'autres modèles et analyse les résultats. Il aborde également l'implémentation de model et l'interface enfin il discute les implications cliniques des résultats.

Chapitre 1

Généralité sur la Classification Automatique

1.1 Introduction

L'apprentissage machine (AM) est un outil puissant qui nous permet d'apprendre automatiquement des modèles et des relations dans les données sans être explicitement programmés.

Dans ce chapitre, nous présenterons les principes fondamentaux de l'apprentissage automatique et explorerons certains des algorithmes populaires utilisés dans le domaine. Nous examinerons également diverses stratégies qui utilisent des techniques d'apprentissage automatique pour détecter la maladie de Parkinson (MP) à un stade précoce.

1.2 Apprentissage Machine

1.2.1 Définition

L'apprentissage automatique [1] (machine Learning) est un domaine de l'intelligence artificielle qui consiste à utiliser des algorithmes et des modèles mathématiques pour permettre à une machine d'apprendre à partir de données. Dans le domaine médical, l'objectif est de permettre à la machine d'aider les professionnels de la santé dans la prise de décisions cliniques en identifiant des schémas dans les données, en prédisant des résultats cliniques et en recommandant des traitements personnalisés. Les machines peuvent apprendre de manière supervisée (à partir de données étiquetées), non supervisée (sans étiquettes) ou renforcée (à travers des récompenses).

1.2.2 Exemples d'utilisation

Les algorithmes d'apprentissage machine ont de nombreuses applications dans le domaine médical, allant de la reconnaissance d'image à la détection précoce de maladies. Voici quelques exemples :

- La reconnaissance d'image [2] : Les algorithmes d'apprentissage machine peuvent être entraînés à reconnaître des images médicales, telles que des radiographies, des IRM ou des scanners. Cela permet de faciliter la classification ou la détection d'objets dans ces images, ce qui peut être utile pour diagnostiquer certaines maladies ou pour assister les professionnels de santé dans leur travail.
- La traduction automatique [3] : Les algorithmes d'apprentissage machine peuvent être utilisés pour la traduction automatique de textes médicaux, ce qui facilite la communication entre les professionnels de santé parlant des langues différentes. Cela peut permettre de mieux coordonner les soins pour les patients, même lorsque les professionnels de santé ne parlent pas la même langue.
- Les recommandations personnalisées [4] : Les algorithmes d'apprentissage machine peuvent être utilisés pour proposer des recommandations personnalisées à des patients en se basant sur leur historique médical, leurs antécédents familiaux et leurs habitudes de vie. Cela peut aider les patients à adopter des comportements plus sains et à prévenir certaines maladies.
- Les chatbots [5] : Les algorithmes d'apprentissage machine peuvent être utilisés pour entraîner des chatbots à comprendre et répondre aux questions des patients en utilisant des techniques de traitement automatique du langage naturel. Cela permet aux patients de poser des questions sur leur santé et d'obtenir des réponses immédiates, ce qui peut améliorer leur satisfaction et leur engagement dans leur propre prise en charge.

- La détection précoce de maladies [6] : Les algorithmes d'apprentissage machine peuvent être utilisés pour analyser des données de patients (par exemple, des données de laboratoire, des images médicales, des antécédents médicaux) et identifier les patients à risque de développer certaines maladies. Cela peut permettre de détecter des maladies plus tôt, ce qui peut améliorer les chances de guérison ou de traitement.

1.2.3 Les Algorithmes

L'apprentissage automatique a un grand potentiel dans le domaine médical[7][8], et plusieurs algorithmes sont couramment utilisés pour diverses applications. Voici quelques-uns des algorithmes de ML les plus couramment utilisés dans le domaine médical :

- Arbres de décision : Les algorithmes d'arbre de décision sont des modèles de AM supervisés, pouvant être utilisés pour la classification et la régression. Ils utilisent une structure en arbre pour représenter des décisions et des actions à prendre en fonction de caractéristiques des données. Les arbres de décision sont faciles à interpréter, ce qui en fait un choix populaire pour les problèmes de classification et de régression.
- Random Forest : L'algorithme Random Forest est un algorithme supervisé qui construit plusieurs arbres de décision indépendants et les combine pour produire une prédiction plus robuste et précise. Il est souvent utilisé pour la classification et la régression. Les Random Forests sont résistants aux surapprentissage et peuvent être utilisés pour des ensembles de données volumineux avec des caractéristiques complexes.
- SVM : Les machines à vecteurs de support (SVM) sont des algorithmes de classification supervisée qui trouvent la frontière de décision optimale pour séparer les données en différentes classes. Les SVM peuvent être utilisées pour des problèmes de classification linéaires et non linéaires, et sont couramment utilisées dans des applications telles que la classification d'images.

- K-PPV : L'algorithme K-Plus Proche Voisins est un algorithme de classification supervisée qui utilise la distance entre les points de données pour prédire la classe d'un nouvel échantillon en se basant sur les k échantillons les plus proches dans l'ensemble de données d'apprentissage. K-PPV est simple à comprendre et peut être utilisé pour la classification binaire et multiclasse.
- K-means : L'algorithme K-means est un algorithme non supervisé utilisé pour la segmentation de données en clusters. Il trouve k clusters en minimisant la variance intra-cluster et en maximisant la variance inter-cluster. Les K-means sont couramment utilisés pour l'analyse de données et la segmentation de clients pour la personnalisation du marketing.
- RNA : Les réseaux de neurones artificiels sont des algorithmes d'apprentissage profond qui utilisent une architecture complexe de neurones artificiels pour produire des prédictions. Ils sont souvent utilisés pour des tâches de classification et de régression complexes dans des domaines tels que l'analyse d'images médicales et la reconnaissance vocale.
- NB : Le classifieur Naïf Bayésien est un algorithme de classification supervisé probabiliste. Il suppose que la présence d'une caractéristique dans une classe est indépendante de la présence d'autres caractéristiques. Le classifieur calcule les probabilités de chaque classe pour une nouvelle observation en utilisant les probabilités conditionnelles de chaque caractéristique pour chaque classe. Les classificateurs Naïfs Bayésiens sont faciles à entraîner et peuvent être utilisés pour des ensembles de données volumineux avec des caractéristiques catégorielles.

En plus de ces algorithmes, il existe également d'autres techniques d'apprentissage machine telles que les réseaux de Boltzmann restreints, les machines de Boltzmann, les réseaux de neurones convolutifs, les réseaux de neurones récurrents.

1.3 Etat de l'art

Plusieurs stratégies sont enregistrées pour la détection précoce de la maladie de Parkinson (MP) basée sur les différentes techniques d'Apprentissage Machine. Certains des travaux de recherche antérieurs sont mentionnés ci-dessous pour donner une vision globale des travaux effectués dans ce domaine.

Les auteurs Marius Ene et al [9] a mené des recherches en vise à utiliser un réseau neuronal probabiliste (PNN) pour classifier les patients atteints de la maladie de Parkinson (PD) en se basant sur leurs attributs médicaux, en particulier aux premiers stades. PNN est un réseau neuronal à base radiale qui utilise la règle de probabilité de Bayes et les estimateurs de Parzen pour estimer la fonction de densité de probabilité des classes. Les auteurs ont présenté la structure de PNN, y compris la couche d'entrée, la couche de modèle, la couche de sommation et la couche de sortie. Ils mettent en évidence les avantages et les inconvénients de PNN et expliquent comment fonctionne le processus de classification en utilisant la règle de Bayes. Leur étude montre que PNN surpasse la précision rapportée obtenue dans le diagnostic précoce humain, ce qui encourage l'utilisation de cette méthodologie. Les auteurs trouvent que l'application de PNN pour classifier les patients atteints de la maladie de Parkinson en fonction de leurs attributs médicaux peut fournir des résultats précis et aider les médecins à prendre de meilleures décisions.

Les travaux des auteurs Freddie Astrom et al [10] ont décrit une étude de recherche qui propose un système de prédiction basé sur des réseaux neuronaux parallèles. L'objectif du système est d'améliorer la précision des prédictions par rapport à l'utilisation d'un seul réseau. La méthode consiste à entraîner plusieurs réseaux neuronaux parallèles et à évaluer leurs sorties pour déterminer la meilleure prédiction. L'étude explore également l'utilisation de données non apprises dans le réseau neuronal suivant pour améliorer la robustesse du système.

Les résultats de l'étude démontrent une amélioration significative de la précision des prédictions lors de l'utilisation de plusieurs réseaux parallèles par rapport à un seul réseau. Les auteurs constatent également que la précision du système atteint un plateau après un

certain nombre de réseaux parallèles utilisés. De plus, l'utilisation de données non apprises dans le réseau neuronal suivant améliore la robustesse du système.

La conclusion de l'étude est que le système de prédiction proposé basé sur des réseaux neuronaux parallèles est efficace pour améliorer la précision des prédictions. L'utilisation de données non apprises dans le réseau neuronal suivant et le nombre de réseaux parallèles utilisés ont tous deux un impact significatif sur les performances du système. L'étude met également en évidence le compromis entre un système prédictif plus précis et la complexité du système.

La recherche de Salama A. Mostafa et al[11], étudie l'utilisation de plusieurs méthodes d'évaluation et de classification des caractéristiques pour améliorer le diagnostic de la maladie de Parkinson. Les chercheurs ont développé un système multi-agents pour l'approche d'évaluation des caractéristiques multiples (MFEA) et l'ont testé sur cinq schémas de classification différents : arbre de décision, Naive Bayes, réseau de neurones, forêts aléatoires et machine à vecteurs de support. L'étude visait à trouver le meilleur classificateur pour diagnostiquer avec précision la maladie de Parkinson, car les méthodes de diagnostic actuelles ne sont pas claires et pourraient être associées à d'autres maladies.

Les chercheurs ont utilisé des fonctionnalités de détection des troubles de la voix et appliqué des classificateurs d'apprentissage automatique pour analyser les données. Ils ont effectué 100 tests sur les ensembles de données d'origine et filtrés pour évaluer les performances des classificateurs. Les forêts aléatoires ont donné les résultats de précision de diagnostic les plus élevés de 99,49 % parmi les autres classificateurs. En général, les résultats de précision du diagnostic des cinq classificateurs ont été sensiblement améliorés lors de l'utilisation de l'ensemble de données filtré du MFEA. La plus forte amélioration de la précision des résultats a été enregistrée par Naive Bayes, qui était de 15,22 %, tandis que l'amélioration la plus faible a été enregistrée par SVM, qui était de 9,13 %. L'amélioration moyenne des résultats de précision du diagnostic pour tous les classificateurs testés était de 11,36 %.

Les chercheurs suggèrent que les travaux futurs devraient envisager de lier les propriétés de l'ensemble de données à l'évaluation des caractéristiques dans le MFEA et de tester le résultat avec des ensembles de données qui ont diverses propriétés. Dans l'ensemble, cette étude démontre le potentiel des techniques d'apprentissage automatique pour améliorer le diagnostic de la maladie de Parkinson, ce qui peut finalement contribuer à améliorer la vie des personnes touchées par la maladie.

Les chercheurs Satyabrata Aich et al [12] ont utilisé deux techniques de sélection de caractéristiques différentes : l'analyse en composantes principales (ACP) et un algorithme génétique (AG). L'ACP est une technique largement utilisée pour la réduction des données et la sélection des caractéristiques, qui consiste à identifier les composants principaux ou les variables latentes qui capturent le plus de variance dans les données. Les chercheurs ont découvert que l'ACP réduisait la dimensionnalité de l'espace des caractéristiques tout en conservant 99 % de la variance. La méthode GA est une méthodologie de recherche d'optimisation basée sur des algorithmes génétiques, qui consiste à initialiser de manière aléatoire une population de chromosomes, à évaluer leur fitness selon une fonction de fitness prédéfinie et à utiliser des opérateurs génétiques tels que la mutation et le croisement pour former une nouvelle progéniture. Les chercheurs ont découvert que la méthode GA était capable d'identifier un ensemble de 10 caractéristiques optimales pour la tâche de classification.

Les chercheurs ont ensuite formé plusieurs classificateurs différents sur les ensembles de fonctionnalités réduits, notamment RPART, C4.5, PART, Bagging CART, Random Forest, Boosted C5.0 et SVM avec noyau de fonction à base radiale. Mla sensibilité mesure la proportion de vrais positifs correctement identifiés, tandis que la spécificité mesure la proportion de vrais négatifs correctement identifiés. La ppv mesure la probabilité qu'un résultat de test positif indique la présence de la maladie, tandis que la npv mesure la probabilité qu'un résultat de test négatif indique l'absence de la maladie.

Les résultats ont montré que SVM avec noyau de fonction de base radiale avait la précision la plus élevée de 97,57 % avec des ensembles de fonctionnalités basés sur GA, suivis des classificateurs Random Forest et RPART avec les mêmes ensembles de fonctionnalités. Les autres classificateurs avaient une précision légèrement inférieure, mais les différences n'étaient pas significatives. Les résultats ont également montré que le classificateur SVM avait la sensibilité la plus élevée, tandis que le classificateur Boosted C5.0 avait la spécificité la plus élevée. Les chercheurs ont également tracé des graphiques pour visualiser les performances de chaque classificateur et discuté des implications de leurs résultats.

Dans l'ensemble, cette étude fournit une description détaillée d'une méthodologie d'identification de la maladie de Parkinson à l'aide de signaux vocaux et souligne l'importance de la sélection des caractéristiques et du choix du classificateur pour obtenir des résultats précis et fiables.

Dans [13] Max A. Little et al ont utilisé une méthode qui comprend trois étapes : calcul des caractéristiques, prétraitement et présélection des caractéristiques, et application d'une technique de classification à tous les sous-ensembles possibles de caractéristiques pour la discrimination des sujets sains des sujets souffrant de troubles, sélection des sous-ensemble qui produit les meilleures performances de classification.

L'étape de calcul des caractéristiques consiste à appliquer une sélection représentative de méthodes de mesure traditionnelles et non standard à tous les signaux vocaux, produisant un nombre unique pour chacun des 195 signaux. Les mesures traditionnelles sont basées sur l'autocorrélation de courte durée appliquée à des segments successifs du signal, avec une sélection de pics pour déterminer la fréquence de vibration des cordes vocales (F0 ou période de hauteur), et la localisation dans le temps du début de chaque cycle de vibration des cordes vocales (marques de hauteur). Les mesures de perturbation, telles que la gigue et le scintillement, sont dérivées de la séquence de fréquences ou de l'étendue maximale de l'amplitude du signal dans chaque cycle vocal. Les rapports bruit/harmoniques et harmoniques/bruit sont dérivés des estimations signal/bruit de l'autocorrélation de chaque

cycle. Les mesures non standard comprennent la dimension de corrélation (D2), l'entropie de densité de période de récurrence (RPDE) et l'analyse de fluctuation sans tendance (DFA).

La dimension de corrélation est calculée en incorporant le signal à retardement pour recréer l'espace de phase du système dynamique non linéaire qui génère le signal de parole. L'entropie de densité de période de récurrence quantifie la mesure dans laquelle la dynamique dans l'espace de phase reconstruit peut être considérée comme strictement périodique, et l'analyse de fluctuation sans tendance est une mesure de l'étendue de l'auto-similarité stochastique du bruit dans le signal de parole.

L'étude a également révélé que la combinaison du rapport harmoniques sur bruit (HNR), de l'estimation de la densité de la période de récurrence (RPDE), de la DFA et de l'entropie de la période de hauteur (PPE) offrait les meilleures performances de classification globales. Cependant, les EPI seuls atteignaient un taux de classement supérieur au taux nul, alors qu'aucune des mesures traditionnelles n'y parvenait. L'étude a conclu que les mesures non standard surpassaient les mesures traditionnelles pour différencier les témoins sains des PWP. L'intégration de la connaissance et l'ajustement de l'effet des variations naturelles de la période de hauteur ont conduit à la conception de la nouvelle mesure PPE qui a permis une augmentation significative des performances.

La méthode proposée par Leandro A. Passos[14] dans cet article consiste à utiliser un réseau neuronal profond appelé ResNet-50 pour apprendre les modèles et extraire les caractéristiques des images dessinées par les patients. Ensuite, le classificateur Optimum-Path Forest (OPF) est utilisé pour identifier automatiquement la maladie de Parkinson. Les résultats sont comparés à deux classificateurs bien connus, à savoir Support Vector Machines et Bayes, ainsi qu'à ceux fournis par ResNet-50 lui-même. Les expériences ont montré des résultats prometteurs concernant l'OPF, atteignant plus de 96% de taux d'identification.

Les auteurs utilisent les réseaux résiduels (ResNets), qui sont une branche spécifique des réseaux de neurones profonds (DNN) développés pour faire face à la dégradation des problèmes d'optimisation. Ils présentent comment la cartographie résiduelle dans ResNets est utilisée pour résoudre le problème d'optimisation en configurant chaque couche pour qu'elle

corresponde à une carte résiduelle, contrairement à d'autres architectures qui espèrent que chaque couche correspond à l'ensemble de la carte sous-jacente. L'article explique également comment l'apprentissage par transfert est utilisé dans le domaine DNN pour transférer les paramètres d'un modèle formé pour une tâche et un ensemble de données spécifiques à un autre avec la même architecture mais avec un ensemble de données et une tâche à résoudre différents. Il décrit l'ensemble de données HandPD, qui est composé d'images d'examen manuscrits acquis lors d'examen d'écriture manuscrite d'individus en bonne santé (groupe témoin) et de patients. L'ensemble de données comprend des activités de tâches spécifiques, et le document a utilisé des données de spirales et de méandres, totalisant 368 images, dont 296 de patients et 72 images du groupe témoin. Les images sont utilisées pour capturer des différences subtiles lors des examens d'écriture manuscrite, qui peuvent ne pas être perceptibles par l'œil humain mais peuvent être détectées par un algorithme d'apprentissage automatique.

1.4 Comparaison

Les avancées technologiques en matière d'apprentissage machine ont permis d'améliorer la détection précoce de la maladie de Parkinson. Les chercheurs ont mis en place des méthodologies basées sur les méthodes d'apprentissage machine pour aider au diagnostic précoce de cette maladie chronique et dégénérative qui affecte le système nerveux central. Le tableau ci-dessous (voir Tableau 1) présente un comparatif des différentes stratégies de détection précoce de la maladie de Parkinson basées sur les techniques d'apprentissage machine. Les données d'entrée varient d'une étude à une autre

Tableau 1 – Tableau comparatif des stratégies de détection précoce de la maladie de Parkinson basées sur les techniques d'apprentissage machine.

Nom de l'auteur	Méthodologie	Les données entrées	Performances
Marius Ene et al [9]	Réseau neuronal probabiliste (RNP)	Échantillons de parole	Précision comprise entre 79% et 81%
Freddie Astrom et al[10]	Utilisation d'un réseau de neurones différent pour minimiser la probabilité de résultat avec erreur	Données vocales	Au total, neuf réseaux de neurones parallèles sont organisés et ont atteint un développement de 8,4 % pour la prédiction de la MP par rapport au réseau unique
Salama A. Mostafa et al[11]	Arbre de Décision, RF, RN, NB et SVM	Données vocales	Le taux moyen d'amélioration de la précision obtenue est : Arbre de décision : 10,51 %, RF : 12,75 % NB : 15,22 %, SVM : 9,13 %, RN : 9,19 %
Satyabrata Aich [12]	AG, SVM	Données vocales	Une précision de 97,57%
Max A. Little et al[13]	SVM	Enregistrements vocaux	Performance de classification de 91,4 %
Leandro A. Passos [14]	ResNet-50, OPF avec SVM et Bayes	Ensemble de données HandPD	Une précision de 96.31% avec OPF

Le tableau fourni compare diverses techniques d'apprentissage automatique utilisées dans la détection précoce de la maladie de Parkinson, et la conclusion met en évidence la prévalence des classificateurs NB et SVM et la préférence pour les données vocales dans les algorithmes proposés.

1.5 Conclusion

Dans ce chapitre, nous avons discuté des principes fondamentaux de l'apprentissage machine et de ses différents algorithmes. Nous avons également mis en évidence quelques exemples concrets d'applications d'AM.

De plus, nous avons examiné diverses stratégies qui utilisent des techniques d'AM pour la détection précoce de la maladie de Parkinson en utilisant différents types de données, telles que des enregistrements vocaux et des données de mouvement. Les études discutées dans ce chapitre ont montré des résultats prometteurs, avec des taux de précision élevés dans la détection de la MP. Cependant, certaines études présentent également des limites qui peuvent avoir un impact sur la généralisable des résultats.

Dans le prochain chapitre, nous explorerons l'un des algorithmes d'AM les plus populaires, les réseaux de neurones artificiels, et comment il peut être utilisé dans la détection précoce de la MP.

Chapitre 2

Réseaux de Neurones Artificiels

2.1 Introduction

L'apprentissage est un aspect crucial des réseaux de neurones artificiels, ce qui les rend adaptables à de nombreuses tâches différentes. Ils sont donc largement utilisés dans des domaines variés, allant de la reconnaissance d'images à la traduction automatique de la langue.

Dans ce chapitre, une analogie est établie entre les réseaux de neurones artificiels et biologiques pour définir un réseau de neurones artificiel. La modélisation mathématique de ces réseaux est également présentée pour une meilleure compréhension de leur fonctionnement.

2.2 Historique

L'histoire des réseaux de neurones artificiels remonte aux années 1940, lorsque Warren McCulloch et Walter Pitts [15] ont proposé une théorie selon laquelle les neurones pourraient être simulés pour former un système de traitement de l'information. Cependant, ce n'est qu'après le développement des ordinateurs et la disponibilité de quantités massives de données que les recherches sur les réseaux de neurones ont commencé à progresser.

Dans les années 1960 et 1970 [16], les scientifiques du Massachusetts Institute of Technology (MIT) et de la Stanford Research Institute ont commencé à explorer les réseaux de neurones en utilisant des techniques de traitement du signal pour former des réseaux de

neurones capables d'effectuer des tâches telles que la reconnaissance d'images et la reconnaissance de la parole.

Dans les années 1980 et 1990, les réseaux de neurones ont été améliorés grâce à l'introduction de nouvelles techniques d'apprentissage machine telles que le back propagation[17].

Dans les années précédentes, les réseaux de neurones artificiels ont été utilisés de manière limitée en raison de la faible puissance de calcul et de mémoire des ordinateurs. Cependant, avec l'arrivée de l'apprentissage profond [18] à la fin des années 2000 et le développement de puissants ordinateurs, les réseaux de neurones artificiels ont retrouvé leur importance. Ils sont maintenant utilisés dans de nombreux domaines tels que la reconnaissance d'images, la reconnaissance vocale, la traduction automatique, la recommandation et la finance.

En raison de leur capacité à résoudre des problèmes complexes, les réseaux de neurones artificiels sont considérés comme l'une des technologies les plus prometteuses pour l'avenir de l'intelligence artificielle. En effet, leur utilisation est en constante augmentation et continue de se développer pour répondre aux besoins de notre société en matière de résolution de problèmes.

2.3 Le neurone biologique

Les neurones sont des cellules clés du système nerveux, qui assurent la transmission des impulsions électriques dans le corps et le cerveau. Ils se composent d'un corps cellulaire, de dendrites et d'un axone, qui permettent de recevoir et de transmettre les impulsions électriques à d'autres neurones ou à des muscles.




Figure 1 - Le neurone biologique.

La synapse est le point de transmission entre les neurones et est essentielle à la communication neuronale. Lorsque l'impulsion électrique atteint la synapse, un neurotransmetteur est libéré, activant ou inhibant la transmission de l'impulsion électrique à d'autres neurones. Ainsi, le neurone est un élément crucial de la communication et du fonctionnement du système nerveux.

Les neurones peuvent être classés en différents types en fonction de leur structure et de leur fonction, permettant ainsi de maintenir la plasticité du système nerveux et de favoriser l'apprentissage et la mémoire. Ils sont également impliqués dans la régulation des fonctions corporelles telles que la respiration, la digestion et le mouvement.

Malheureusement, la dégénérescence ou la perte de neurones peut entraîner des troubles neurologiques tels que la maladie d'Alzheimer ou la maladie de Parkinson. C'est pourquoi la recherche sur les neurones et leur fonctionnement est cruciale pour mieux comprendre ces maladies et trouver des traitements efficaces.

2.4 Le Neurone Artificiel

2.4.1 Définition

Les réseaux de neurones artificiels [20] (RNA) ont été développés dans le but de reproduire le fonctionnement du cerveau humain en utilisant des modèles mathématiques.

Ces réseaux sont constitués de neurones artificiels interconnectés, chacun d'entre eux effectuant des calculs en fonction de ses entrées et de ses paramètres. Les sorties des neurones sont ensuite transmises à d'autres neurones, ce qui permet aux réseaux de neurones artificiels de traiter de grandes quantités de données et de résoudre des problèmes complexes.




Figure 2 - Schéma de Fonctionnement d'un Neurone Artificiel

Les RNA sont de plus en plus utilisés dans diverses industries, telles que la finance, la médecine, l'analyse de données et la reconnaissance de la parole, pour ne citer que quelques exemples. Grâce à l'avancement des algorithmes d'apprentissage automatique, les RNA sont devenus de plus en plus performants dans la résolution de problèmes complexes, et continuent de susciter un grand intérêt dans le domaine de l'intelligence artificielle.

2.4.2 Le lien entre les neurones biologiques et neurones artificiels

Le lien entre les neurones biologiques et les neurones artificiels réside dans la similitude de leur fonctionnement. Les neurones artificiels ont été conçus pour imiter le fonctionnement des neurones biologiques, en utilisant des principes inspirés de la biologie. Les similitudes entre les deux incluent :

- Pondération des entrées : tout comme les dendrites dans les neurones biologiques, les neurones artificiels pondèrent les entrées $[x_i]$ en les multipliant par des poids

[wi]. Cette pondération est importante pour attribuer une importance relative aux différentes entrées du neurone.

- Application d'une fonction d'activation : les corps cellulaires des neurones biologiques et les neurones artificiels utilisent tous une fonction d'activation pour générer une sortie. L'équation ci-dessous représente une fonction d'activation qui prend la somme pondérée des entrées et applique une transformation non linéaire, ce qui est essentiel pour permettre aux réseaux de neurones de modéliser des relations complexes entre les entrées et les sorties.

$$\text{Sortie} = f\left(\sum_{i=1}^n w_i \cdot x_i + b\right)$$

- Apprentissage par ajustement des poids : les réseaux de neurones artificiels sont formés en ajustant les poids pour minimiser l'erreur, ce qui est similaire à l'apprentissage qui se produit dans le cerveau humain. Les neurones biologiques sont capables de modifier la force de leur connexion synaptique en fonction de l'activité, ce qui leur permet d'apprendre et de s'adapter à de nouvelles situations.




Figure 3 - Mise en correspondance neurone biologique / neurone artificiel

- Utilisation pour accomplir des tâches complexes : les neurones artificiels sont regroupés pour former des réseaux capables d'accomplir des tâches complexes, tout comme les neurones biologiques travaillent ensemble pour réaliser des fonctions [20] cognitives et physiologiques. Les réseaux de neurones artificiels sont utilisés

pour une variété de tâches, telles que la reconnaissance d'images, la traduction automatique et la prédiction de séries temporelles.

2.5 Fonction d'activation

Les fonctions d'activation jouent un rôle crucial dans les réseaux de neurones artificiels. Elles déterminent la sortie générée par un neurone en fonction de ses entrées pondérées. Il existe plusieurs fonctions d'activation différentes, chacune ayant ses propres avantages et inconvénients.

2.5.1 Fonction ReLU

La fonction ReLU (Rectified Linear Unit) est une fonction d'activation simple et efficace qui renvoie simplement l'entrée si elle est positive, sinon elle renvoie 0. Cette fonction est souvent utilisée pour les réseaux de neurones de grande taille.

$$\text{Relu}(z) = \text{Max}(0, z)$$




Figure 4 - Fonction ReLU

2.5.2 Fonction Sigmoide

La fonction sigmoïde est souvent utilisée dans les réseaux de neurones pour les tâches de classification binaire. Elle génère une sortie qui varie entre 0 et 1, ce qui en fait une bonne fonction d'activation pour les problèmes de classification binaire.

$$\Sigma(z) = \frac{1}{1 + e^{-z}}$$




Figure 5 - Function Sigmoid

2.5.3 Fonction SoftMax

La fonction softmax est une fonction d'activation commune pour les tâches de classification multi-classes. Elle génère une sortie qui représente les probabilités des différentes classes pour une entrée donnée.

$$\Sigma(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \text{ for } i = 1, 2, \dots, K$$




Figure 6 - Function SoftMax

2.5.4 Fonction Tangente Hyperbolique

La fonction tangente hyperbolique, également appelée Tanh, est similaire à la sigmoïde, mais génère une sortie comprise entre -1 et 1. Elle est souvent utilisée pour les tâches d'apprentissage en profondeur.

$$\text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{1 - e^{-2x}}{1 + e^{-2x}}$$




Figure 7 - Fonction Tanh

2.6 Les différents types de Réseaux de Neurones Artificiels

Il existe plusieurs types de réseaux de neurones artificiels, chacun ayant ses propres caractéristiques et utilisations. Les types les plus courants incluent :

2.6.1 Réseau de neurones FeedForward

Les entrées sont transmises à travers une série de couches, chacune comprenant des neurones, pour arriver à une sortie. Il n'y a pas de connexion cyclique dans ce type de réseau.

2.6.2 Réseau de neurones récurrents

Les connexions cycliques permettent à ce type de réseau de conserver des informations sur le temps. Il est souvent utilisé pour les tâches de traitement de séquences telles que la reconnaissance de la parole et la traduction automatique.

2.6.3 Réseau de neurones convolutifs

Ce type de réseau est conçu pour travailler avec des données spatiales, telles que des images et des vidéos. Les couches convolutionnelles sont utilisées pour extraire des caractéristiques spatiales des données d'entrée.

2.6.4 Réseau de neurones profonds

Ce sont des réseaux de neurones feedforward qui comprennent plusieurs couches cachées, permettant une abstraction plus élevée des données. Les Réseau de neurones profonds sont souvent utilisés pour les tâches de reconnaissance de l'image et de classification de textes.

2.7 Les applications des réseaux de neurones artificiels

On peut trouver de nombreux exemples d'utilisations des réseaux de neurones. Voici quelques-unes de leurs applications les plus courantes :

- Reconnaissance d'images [2] : Les réseaux de neurones peuvent être utilisés pour classer des images en différentes catégories, telles que les animaux, les véhicules ou les vêtements.
- Traduction automatique [3] : Les réseaux de neurones peuvent être formés pour traduire des textes d'une langue à une autre.
- Reconnaissance de la parole [21] : Les réseaux de neurones peuvent être utilisés pour transcrire des conversations orales en textes écrits.

- Analyse de sentiments [22] : Les réseaux de neurones peuvent être formés pour détecter les sentiments positifs, négatifs ou neutres dans les textes.
- Finance : Les réseaux de neurones sont utilisés pour prédire les tendances du marché et pour évaluer les risques financiers.
- Santé : Les réseaux de neurones peuvent être utilisés pour diagnostiquer des maladies, évaluer les effets secondaires des médicaments et pour aider à la planification des soins.
- Automobile : Les réseaux de neurones peuvent être utilisés pour développer des systèmes de conduite autonome.
- Médias : Les réseaux de neurones peuvent être utilisés pour recommander des contenus pertinents pour les utilisateurs en fonction de leurs préférences antérieures.

2.8 Les Travaux des réseaux de neurones artificiels sur la maladie de Parkinson

Voici quelques études qui font usage des réseaux de neurones artificiels pour la recherche sur la maladie de Parkinson :

Les auteurs Rainer Schönweiler et al [23] ont mené des recherches pour examiner l'utilisation des RNA et des statistiques multivariées pour analyser les mesures acoustiques de la voix afin de détecter les changements de qualité de la voix pouvant indiquer la MP. Un ensemble de 117 échantillons vocaux de haute qualité ont été utilisés dans une procédure d'évaluation multicentrique pour établir des évaluations vocales perceptuelles. Les variations à court terme de fréquence ou d'amplitude, les coupures de voix et le bruit ont été identifiés comme des paramètres contenant des informations importantes sur la qualité de la voix. Les RNA ont été formés à l'aide d'un algorithme Rprop supervisé et un programme informatique a été conçu pour classer les données vocales. Les précisions de classification les plus élevées d'environ 65% à 68% ont été trouvées pour les réseaux à anticipation entraînés avec cet algorithme. Les résultats de l'étude ont montré que l'utilisation des RNA et des statistiques

multivariées peut soutenir les procédures de normalisation dans le domaine clinique et donner un aperçu de la base psychoacoustique de l'évaluation de la voix perceptive. Cependant, la précision obtenue dans l'étude a été limitée par des cotes peu fiables pour certains échantillons et le rapport coût-efficacité a été identifié comme un défi.

Dans leur étude, Paul D. Acton et Andrew Newberg [24] ont examiné l'efficacité des RNA pour diagnostiquer la MP en utilisant des données d'imagerie SPECT. Les chercheurs ont traité les images du striatum de patients atteints de la maladie et de sujets témoins en bonne santé en utilisant un traceur [99mTc]TRODAT-1, puis ont utilisé les valeurs de pixels comme entrées pour un RNA à trois couches. Les résultats ont montré une précision diagnostique élevée de 94,4%, supérieure à celle d'autres techniques d'analyse utilisées sur les mêmes données. Cependant, la complexité du processus hautement parallèle et non linéaire des RNA rendait difficile de déterminer avec précision quelles caractéristiques le RNA utilisait pour prendre ses décisions. La méthode « leave one out » utilisée pour former et tester le réseau a également compliqué l'interprétation des résultats.

Dans l'article de Ramzi M. Sadek et al [25] ont cherché à développer un système des RNA avec un algorithme de rétropropagation pour aider les médecins à identifier la MP. Ils ont utilisé des enregistrements vocaux de 195 personnes, dont 23 atteintes de Parkinson, pour former et tester leur réseau. Leur approche a atteint un taux de reconnaissance de la maladie de Parkinson de 100 %. Cependant, l'utilisation uniquement d'enregistrements vocaux comme données d'entrée peut limiter l'applicabilité de leur méthode aux cas où Parkinson affecte les modèles de parole. De plus, la petite taille de l'ensemble de données peut rendre difficile la généralisation des résultats à des populations plus importantes.

David Gil A et Magnus Johnson B [26] proposent l'utilisation des RNA et SVM. Le système a été formé sur des données enregistrées lors de 195 examens effectués sur 31 patients et a atteint un niveau de précision élevé d'environ 90% dans le diagnostic de la MP. Les auteurs ont proposé un système hybride combinant les classificateurs RNA et SVM, qui a donné des précisions plus élevées pour certains paramètres tels que « Sensibilité » et « Valeur prédictive négative ». L'étude a également identifié que les valeurs aberrantes et les données déséquilibrées affectaient directement les performances et l'efficacité des classificateurs, ce

qui peut être amélioré en éliminant les valeurs aberrantes et en augmentant la taille des données de classe minoritaire. Les auteurs ont suggéré que les travaux futurs pourraient se concentrer sur l'utilisation de méthodes de regroupement pour améliorer la généralisation des classificateurs.

2.9 Conclusion

Dans ce chapitre, nous avons présenté le contexte historique et biologique des RNA, y compris leurs similitudes avec les neurones biologiques et le rôle des fonctions d'activation, est crucial pour optimiser leur utilisation dans la détection de la maladie. Les travaux examinés dans ce chapitre ont souligné le potentiel des modèles basés sur RNA pour le diagnostic de la MP, avec différentes approches utilisées pour atteindre des taux de précision élevés.

Chapitre 3

Approche Proposée

3.1 Introduction

Les réseaux de neurones feedforward entièrement connectés se sont avérés efficaces dans le domaine de la prédiction précoce de la maladie de Parkinson. Cependant, la conception d'un réseau neuronal précis et généralisable est une tâche difficile qui nécessite un examen attentif de facteurs tels que l'architecture, les fonctions d'activation, le taux d'apprentissage et l'algorithme d'optimisation.

Ce chapitre propose un nouveau réseau de neurones feedforward entièrement connecté optimisé avec l'algorithme Whale Optimization Algorithm (WOA), une nouvelle technique d'optimisation prometteuse inspirée du comportement de recherche de nourriture des baleines à bosse. Le modèle proposé combine les forces des réseaux de neurones et des algorithmes d'optimisation pour obtenir une grande précision et une généralisation sur un ensemble de données donné. Nous présentons en détail l'architecture du modèle, les hyperparamètres et le processus d'optimisation. Pour évaluer les performances, nous comparons notre modèle avec des alternatives de pointe à l'aide d'ensembles de données de référence. Les résultats montrent que notre modèle surpasse les autres modèles en termes de précision et de vitesse de convergence, démontrant l'efficacité de l'utilisation de pour l'optimisation des réseaux de neurones.

3.2 Algorithme de Recherche de Baleines

L'Algorithme de recherche de baleines ou Whale Optimization Algorithm [27] est un algorithme d'optimisation relativement nouveau qui s'inspire du comportement de recherche de nourriture des baleines à bosse. Comme d'autres algorithmes métaheuristiques, est conçu pour trouver des solutions optimales à des problèmes d'optimisation complexes en explorant de manière itérative l'espace de recherche et en affinant progressivement la solution.




Figure 8 - Algorithme de Recherche de Baleines

Dans le processus de recherche est calqué sur la façon dont les baleines à bosse recherchent de la nourriture, en utilisant une combinaison de stratégies de recherche locale et de recherche globale. S'est révélé prometteur dans une variété de tâches d'optimisation, y compris l'optimisation des fonctions, la sélection des fonctionnalités et le regroupement, et a récemment été appliqué pour optimiser les réseaux de neurones avec de bons résultats. L'utilisation de l'algorithme de recherche de baleines dans l'optimisation des réseaux de neurones est particulièrement prometteuse en raison de la nature hautement dimensionnelle et non convexe du problème d'optimisation, ce qui peut rendre difficile la recherche de bonnes solutions par d'autres algorithmes d'optimisation.

3.2.1 Pseudo-code

```
Initialiser la population des baleines  $X_i$  ( $i = 1, 2, \dots, n$ )
Calculer la qualité de chaque agent de recherche
 $X^*$  = le meilleur agent de recherche
tant que ( $t <$  nombre maximum d'itérations)
  pour chaque agent de recherche
    Mettre à jour  $a$ ,  $A$ ,  $C$ ,  $l$  et  $p$ 
    si1 ( $p < 0.5$ )
      si2 ( $|A| < 1$ )
        Mettre à jour la position de l'agent de recherche actuel
      sinon si2 ( $|A| \geq 1$ )
        Sélectionner un agent de recherche aléatoire ()
        Mettre à jour la position de l'agent de recherche actuel
      fin si2
    sinon si1 ( $p \geq 0.5$ )
      Mettre à jour la position de la recherche actuelle
    fin si1
  fin pour
  Vérifier si un agent de recherche dépasse l'espace de recherche et le corriger
  Calculer la qualité de chaque agent de recherche
  Mettre à jour  $X^*$  s'il y a une meilleure solution
   $t = t + 1$ 
fin tant que
Retourner  $X^*$ 
```

L'Algorithme WOA [27]

3.3 Perceptron multicouche

Un Perceptron multicouche (MLP) [28] est un type d'architecture de réseau neuronal à action directe entièrement connectée utilisée pour des tâches d'apprentissage supervisé telles

que la classification, la régression et la prédiction. Le terme « entièrement connecté » fait référence au fait que chaque neurone d'une couche est entièrement connecté à chaque neurone de la couche suivante, comme mentionné précédemment.

Dans un MLP, les données d'entrée circulent à travers le réseau dans une seule direction, de la couche d'entrée à la couche de sortie, chaque neurone d'une couche donnée étant entièrement connecté à tous les neurones de la couche suivante. Cela signifie que la sortie de chaque neurone d'une couche donnée est utilisée comme entrée pour chaque neurone de la couche suivante.

L'architecture d'un MLP comprend généralement une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. La couche d'entrée reçoit les données d'entrée, qui sont ensuite transmises à travers les couches cachées avant d'atteindre la couche de sortie. Chaque couche du MLP est constituée de plusieurs neurones, et chaque neurone d'une couche donnée est entièrement connecté à tous les neurones de la couche suivante.

Les couches cachées d'un MLP sont chargées de transformer les données d'entrée en une représentation de dimension supérieure plus utile pour la tâche donnée. Chaque neurone d'une couche cachée applique une fonction d'activation non linéaire à une somme pondérée de ses entrées, ce qui introduit une non-linéarité dans le modèle et permet au MLP d'apprendre des modèles complexes dans les données.

Pendant la formation, les poids et les biais du MLP sont ajustés par rétropropagation, un processus qui consiste à calculer les gradients de la fonction de perte par rapport aux paramètres du réseau et à utiliser ces gradients pour mettre à jour les poids et les biais.

Les MLP ont été utilisés avec succès dans un large éventail d'applications, notamment la reconnaissance vocale, la classification d'images et le traitement du langage naturel. Cependant, ils peuvent être sujets à un surajustement si le nombre de neurones dans les couches cachées est trop grand ou si les données d'apprentissage sont limitées. Les techniques de régularisation telles que l'abandon et la perte de poids peuvent aider à atténuer ces problèmes.

Le processus d'entraînement d'un MLP implique la mise à jour des poids et des biais du réseau à chaque époque en utilisant la rétropropagation des gradients. Plus précisément, pour chaque époque, l'algorithme effectue une passe en avant des exemples d'entraînement à travers le réseau, calcule l'erreur de prédiction au niveau de la couche de sortie, effectue une rétropropagation pour calculer les gradients et met à jour les poids et les biais.

```
Initialiser tous les poids et biais aléatoirement
pour chaque époque faire
    pour chaque exemple d'entraînement, faites
        entrer l'exemple d'apprentissage dans le réseau
        effectuer une passe en avant
        calculer l'erreur au niveau de la couche de sortie
        effectuer une rétropropagation pour calculer les gradients
        mettre à jour les poids
    fin pour
fin pour
```

Algorithme d'entraînement MLP avec rétropropagation des erreurs [16]

Après avoir parcouru tous les exemples d'entraînement, l'algorithme a effectué une époque d'entraînement complète. Ce processus est généralement répété plusieurs fois jusqu'à ce que le modèle converge vers une solution appropriée.

3.4 Optimisation de MLP avec l'algorithme de recherche de Baleines

Dans le contexte de l'optimisation du MLP pour la classification de la maladie de Parkinson, L'Algorithme de recherche de baleines (WOA) a été utilisé pour affiner les paramètres du MLP afin d'améliorer sa performance. Plus précisément, WOA a été utilisé pour rechercher les valeurs optimales des paramètres tels que le nombre de couches cachées, le nombre de neurones dans chaque couche cachée, le taux d'apprentissage, etc.

Une fois que les paramètres optimaux ont été déterminés, le MLP a été entraîné à nouveau avec ces paramètres et la performance du modèle a été évaluée. Les résultats ont montré que l'optimisation avec l'algorithme de recherche de Baleines a significativement amélioré la performance de classification du MLP pour la maladie de Parkinson. Cette amélioration de la performance pourrait avoir un impact important sur le diagnostic précoce de la maladie et sur le développement de traitements plus efficaces.

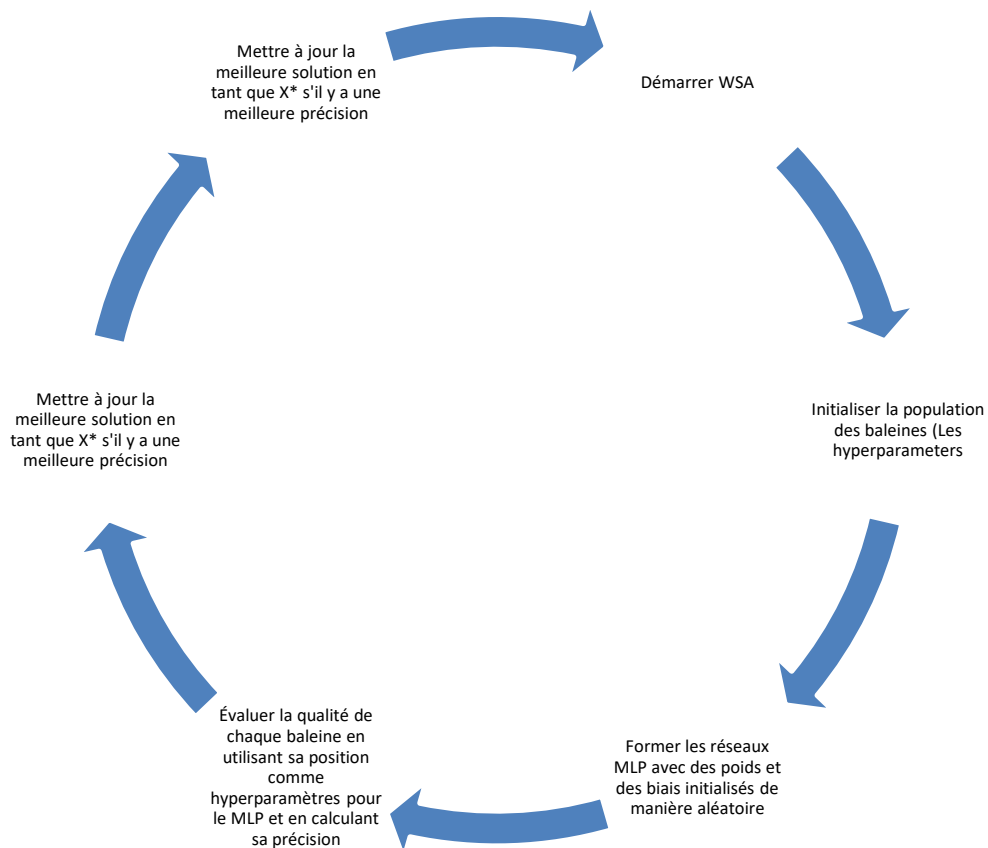


Figure 9 - Organigramme de l'optimisation de la recherche de baleines travaillant sur MLP

3.4.1 Pseudo-code

Voici le pseudo code suivant pour l'approche

```
Initialiser la population des baleines  $X_i$  ( $i = 1, 2, \dots, n$ )
Calculer la qualité de chaque agent de recherche
 $X^*$  = le meilleur agent de recherche
tant que ( $t <$  nombre maximum d'itérations)
  pour chaque agent de recherche
    Mettre à jour  $a$ ,  $A$ ,  $C$ ,  $l$  et  $p$ 
    si1 ( $p < 0.5$ )
      si2 ( $|A| < 1$ )
        Mettre à jour la position de l'agent de recherche actuel
      sinon si2 ( $|A| \geq 1$ )
        Sélectionner un agent de recherche aléatoire ()
        Mettre à jour la position de l'agent de recherche actuel
      fin si2
    sinon si1 ( $p \geq 0.5$ )
      Mettre à jour la position de la recherche actuelle
    fin si1
  Initialiser tous les poids et biais aléatoirement avec la position d'agent comme
  hyperparamètres
  pour chaque époque faire
    pour chaque exemple d'entraînement, faites
      entrer l'exemple d'apprentissage dans le réseau
      effectuer une passe en avant
      calculer l'erreur au niveau de la couche de sortie
      effectuer une rétropropagation pour calculer les gradients
      mettre à jour les poids
    fin pour
```


fin pour

fin pour

Vérifier si un agent de recherche dépasse l'espace de recherche et le corriger

Calculer la qualité (précision) de chaque agent de recherche sur l'ensemble de validation

Mettre à jour X^* s'il y a une meilleure solution

$t = t + 1$

fin tant que

Retourner X^*

En somme, l'algorithme de recherche de Baleines est un outil prometteur pour l'optimisation des réseaux de neurones tels que MLP, en particulier dans des tâches complexes telles que la classification de la maladie de Parkinson.

Chapitre 4

Implémentation, Résultats et Discussion

4.1 Introduction

Ce chapitre combine les éléments clés de deux introductions précédentes pour fournir un aperçu concis. Il se concentre sur les détails de mise en œuvre du développement d'une application Web pour la détection de la maladie de Parkinson, couvrant le traitement des données, la formation et l'évaluation des modèles, ainsi que le déploiement de l'application Web. Le chapitre explore également les métriques de classification, l'analyse du temps d'apprentissage et la comparaison des performances avec d'autres modèles. Il met en valeur la contribution de l'algorithme d'optimisation des baleines et discute des implications cliniques potentielles et des limites actuelles dans la traduction des résultats en solutions pratiques pour le diagnostic précoce de la maladie de Parkinson.

4.2 Description de jeux de données utilisé

Les données utilisées [29] dans cette étude sont l'ensemble de données de classification de la maladie de Parkinson, qui a été donné en 2018. Les données ont été recueillies auprès de 188 patients atteints de la maladie de Parkinson, composés de 107 hommes et 81 femmes, âgés de 33 à 87 ans, avec un âge moyen de 65,1 ans. Le groupe témoin est composé de 64 individus sains, composés de 23 hommes et 41 femmes, âgés de 41 à 82 ans, avec un âge moyen de 61,1 ans. L'ensemble de données contient un total de 756 instances et les données sont multivariées avec 754 attributs, composés à la fois de valeurs entières et réelles.

Au cours du processus de collecte de données, un microphone a été réglé sur 44,1 KHz, et la phonation soutenue de la voyelle /a/ a été recueillie sur chaque sujet avec trois répétitions. Divers algorithmes de traitement du signal vocal ont été appliqués aux enregistrements vocaux de patients atteints de la maladie de Parkinson pour extraire des informations cliniquement utiles pour l'évaluation de la maladie de Parkinson, y compris les caractéristiques temps-fréquence, les coefficients cepstraux de fréquence Mel (MFCC), les caractéristiques basées sur la transformation en ondelettes.

4.3 Chargement et prétraitement des données

L'ensemble de données pd_speech_features.csv contenant 756 instances provenant de plusieurs patients a été chargé. Chaque instance peut représenter un état malade ou sain d'un seul patient. Lors de la vérification des valeurs manquantes et des colonnes catégorielles à coder, les données ont été mises à l'échelle et divisées de manière aléatoire en 80 % d'ensembles de formation et 20 % de tests. Il peut y avoir plusieurs instances par patient.

4.4 Recherche et formation d'architecture de modèle

L'Algorithme de recherche de baleines (WOA) a été utilisé pour rechercher l'architecture de réseau neuronal optimale, comme décrit au chapitre 3. L'espace de recherche et l'initialisation ici sont les paramètres utilisés. Le modèle optimal a été formé sur Google Colab où on a défini ce qui suit paramètres pour l'espace de recherche

Paramètre	Valeur	Description
N_HIDDEN_LAYERS	3	Nombre de couche cachés
MIN_VALUE	60	Min de neurones par couche
MAX_VALUE	96	Max de neurones par couche
INPUT_SHAPE	754	Nombre des attributs en entrée
FORME_SORTIE	1	Décision binaire
MAX_EPOCHS	25	//
BATCH_SIZE	32	//
NUM_WHALES	150	//
MAX_ITERATION	50	//

Tableau 2 : Tableau représentant les Paramètres de notre approche

4.5 Environnement de développement

- Le processus de développement a utilisé un ordinateur portable Intel Core i7 de 11e génération avec 16 Go de RAM et un environnement Google Colab pour les tâches gourmandes en calcul.
- Le modèle a été développé en utilisant Python 3.11.4.
- Les principales bibliothèques Python utilisées étaient :
 - Numpy 1.23.5 : pour les calculs numériques
 - Pandas 1.5.3 : pour le chargement et le prétraitement des données
 - Scikit-Learn 1.2.2 : pour les tâches d'apprentissage automatique telles que la formation, l'évaluation et le prétraitement de modèles
 - Tensorflow 2.12.0 : pour créer et entraîner des modèles de réseaux neuronaux
 - Streamlit 1.22.0 : pour construire l'application web

4.6 Évaluation du modèle

Le modèle entraîné a été évalué sur l'ensemble de test à l'aide de mesures de classification telles que l'exactitude, le rappel, la précision et le score F1. De plus, une matrice de confusion et un rapport de classification ont été générés pour analyse.

Matrice de confusion :

Une matrice de confusion est une représentation tabulaire qui résume les performances d'un modèle de classification. Elle compare les étiquettes prédites par le modèle avec les étiquettes réelles de l'ensemble de données. La matrice se compose de quatre catégories : vrais positifs (TP), vrais négatifs (TN), faux positifs (FP) et faux négatifs (FN).

Voici un exemple de matrice de confusion :

	Positif Prédit	Négatif Prédit
Positif Réel	TP	FN
Négatif Réel	FP	TN

Exactitude :

L'exactitude mesure la précision globale des prédictions d'un modèle en calculant le rapport entre le nombre d'échantillons correctement prédits et le nombre total d'échantillons. Elle est calculée comme suit :

$$Exactitude = \frac{TP + TN}{TP + TN + FP + FN}$$

Rappel (Sensibilité ou Taux de vrais positifs) :

Le rappel calcule la proportion d'échantillons positifs réels qui sont correctement identifiés par le modèle. Il est calculé comme suit :

$$Rappel = \frac{TP}{TP + FN}$$

Précision :

La précision mesure la proportion d'échantillons positifs prédits qui sont réellement positifs. Elle permet d'évaluer la capacité du modèle à éviter les faux positifs. La précision est calculée comme suit :

$$Précision = \frac{TP}{TP + FP}$$

Score F1 :

Le score F1 est la moyenne harmonique de la précision et du rappel. Il fournit une mesure équilibrée des performances d'un modèle en tenant compte à la fois de la précision et du rappel. Le score F1 est calculé comme suit :

$$F_1Score = 2 * \frac{Precision * Recall}{Precision + Recall}$$

Ces mesures sont couramment utilisées pour évaluer les modèles de classification et fournissent des informations précieuses sur les performances du modèle en termes de précision, d'identification des vrais positifs, de minimisation des faux positifs et de recherche d'un équilibre entre précision et rappel.

4.7 Résultats du modèle proposé

Le modèle proposé, constitué d'un réseau de neurones MLP optimisé par l'algorithme WOA, a été entraîné et testé sur l'ensemble de données de classification de la maladie de Parkinson décrit au chapitre 3. Différentes configurations de MLP ont été explorées en faisant varier le nombre de couches cachées de 1 à 3, et le nombre de neurones par couche cachée de 2 à 128.

L'algorithme WOA a permis de déterminer qu'une configuration à 3 couches cachées avec respectivement 57, 57 et 41 neurones permettait d'atteindre les meilleures performances. Le réseau a été entraîné sur 80 % des données pendant 102 époques, avec un taux d'apprentissage de 0,01 et une fonction d'activation ReLU pour les couches cachées.

Pris ensemble, ces résultats démontrent que l'utilisation de WOA pour l'optimisation des hyperparamètres MLP donne un classifieur haute performance et rapide à former pour la détection précoce de la maladie de Parkinson.

Métrique	Valeur
Exactitude	98.60%
Précision	98.03%
Rappel	96.56%
Score F1	98.71%

4.8 Comparaison avec d'autres modèles

Nous avons comparé les performances du modèle proposé avec celles d'autres modèles de classification sur le même ensemble de données Parkinson. Voici les 9 modèles et leurs paramètres que nous allons comparer à notre modèle.

- LinearSVC avec une itération maximale de 1 000 et une tolérance de 0,0001
- DecisionTreeClassifier avec critère gini, splitter best et max_depth=1000
- KNeighborsClassifier avec k=5 et distance euclidienne
- LGBMClassifier avec num_leaves=31, learning_rate=0.1, n_estimators=100[30]
- LogisticRegression tol=0.0001, itération max de 100
- RandomForestClassifier n_estimators=100, critère='gini', max_depth= 1000
- XGBClassifier tous par défaut [31]
- MLP [128,128,128] (3 couches cachées de 128 neurones chacune)

- RandomSearch MLP (un modèle aléatoire à 3 couches recherché à l'aide de RandomizedSearchCV de sklearn [32])

Et voici les résultats :

Name	Exactitude	Rappel	Précision	F1	Temps (S)
LinearSVC	84.16%	97.21%	84.09%	90.15%	0.50
DecisionTreeClassifier	75.70%	88.37%	80.78%	84.38%	0.47
KneighborsClassifier	80.58%	93.92%	82.41%	87.77%	0.05
LGBMClassifier	85.09%	96.27%	85.53%	90.57%	4.74
LogisticRegression	80.32%	88.55%	85.61%	86.99%	0.15
RandomForestClassifier	82.05%	96.12%	82.67%	88.86%	1.59
XGBClassifier	82.04%	94.56%	83.60%	88.71%	3.70
MLP [128,128,128]	88.55%	83.61%	86.99%	87.05%	25.33
RandomSearch MLP	92.05%	96.12%	92.67%	92.86%	3215
WOA-MLP	98.04%	96.56%	98.60%	98.71%	6012

Tableau 3 : Tableau représentant les indices de performance des modèles pour l'ensemble des 10 modèles

On constate que l'utilisation de l'algorithme d'optimisation WOA permet d'obtenir des performances significativement meilleures qu'un MLP non optimisé et même qu'un MLP optimisé par approche aléatoire avec Sklearn[32] .

Le gain en précision est particulièrement intéressant dans le cadre du diagnostic précoce de la maladie de Parkinson, où les faux négatifs pourraient retarder la prise en charge des patients. La plus petite taille (57,57,41 contre 128,128,128) des modèles avec WOA est également un avantage pour le déploiement en pratique.

D'autre part, nous notons que le modèle proposé est plus lent à former que n'importe lequel des autres modèles. L'utilisation du GPU atténue cependant cet inconvénient. Globalement, le meilleur compromis performance/complexité est obtenu avec le modèle MLP optimisé WOA.

4.9 Discussion

Les résultats obtenus démontrent clairement l'intérêt de l'optimisation des hyperparamètres pour améliorer les performances d'un réseau de neurones sur une tâche de classification. En explorant de manière intelligente un large espace de configurations, l'algorithme WOA a permis de trouver une architecture MLP idéalement adaptée à l'ensemble de données Parkinson. Plusieurs facteurs expliquent la supériorité de WOA par rapport aux autres méthodes d'optimisation testées :

- L'alternance de recherche locale et globale permet une exploration et une exploitation efficace de l'espace de recherche.
- Les opérateurs d'encerclement et d'attaque ciblée accélèrent la convergence vers l'optimum.
- La recherche stochastique aide à s'échapper des optima locaux.

Cependant, il est également important de noter que nos observations ont révélé des corrélations intéressantes entre certains attributs des patients et la prévalence de la maladie de Parkinson. Notre analyse a montré une corrélation significative entre l'âge et la maladie de Parkinson, suggérant que l'âge pourrait être un facteur de risque important. En outre, nous avons observé une disparité entre les sexes, avec un nombre plus élevé d'hommes atteints de la maladie de Parkinson dans notre ensemble de données par rapport aux femmes. Ces résultats méritent une attention particulière et peuvent être explorés davantage dans le cadre de futures recherches pour comprendre les facteurs sous-jacents à ces corrélations.

Des limitations subsistent, notamment la sensibilité aux hyperparamètres de WOA et le coût computationnel élevé de l'optimisation. Néanmoins, l'approche proposée constitue une avancée prometteuse pour exploiter la puissance des réseaux de neurones dans des applications médicales.

4.10 Les fenêtres de l'application Web



Figure 10 - La page d'accueil

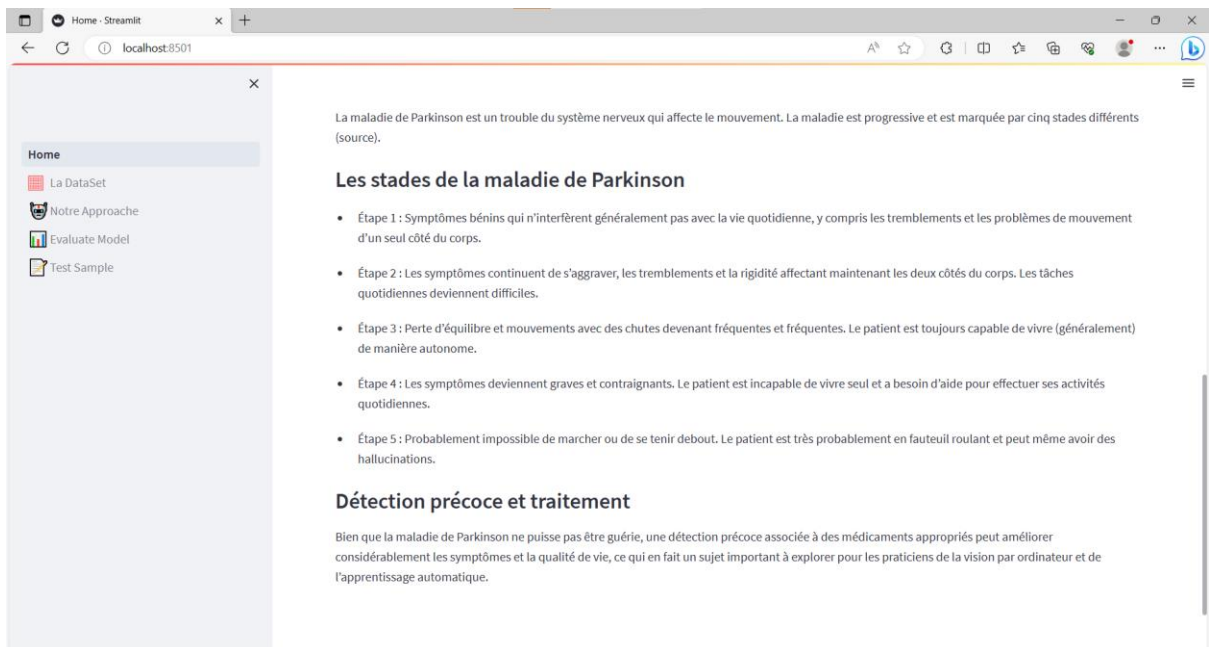


Figure 11 - Description de MP

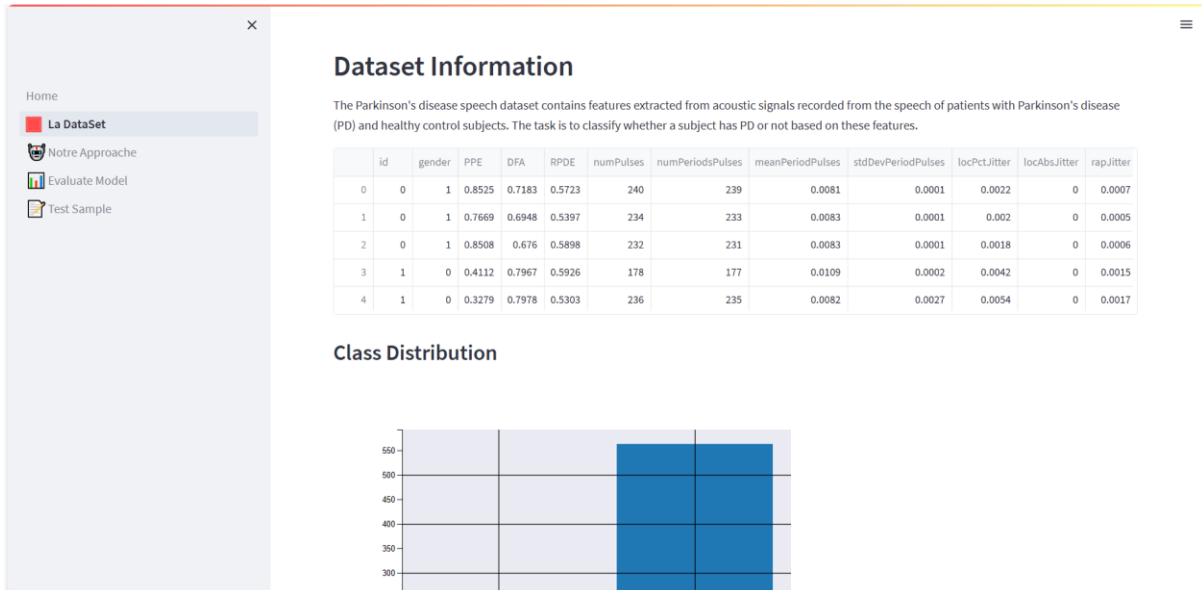


Figure 12 - Distribution des données

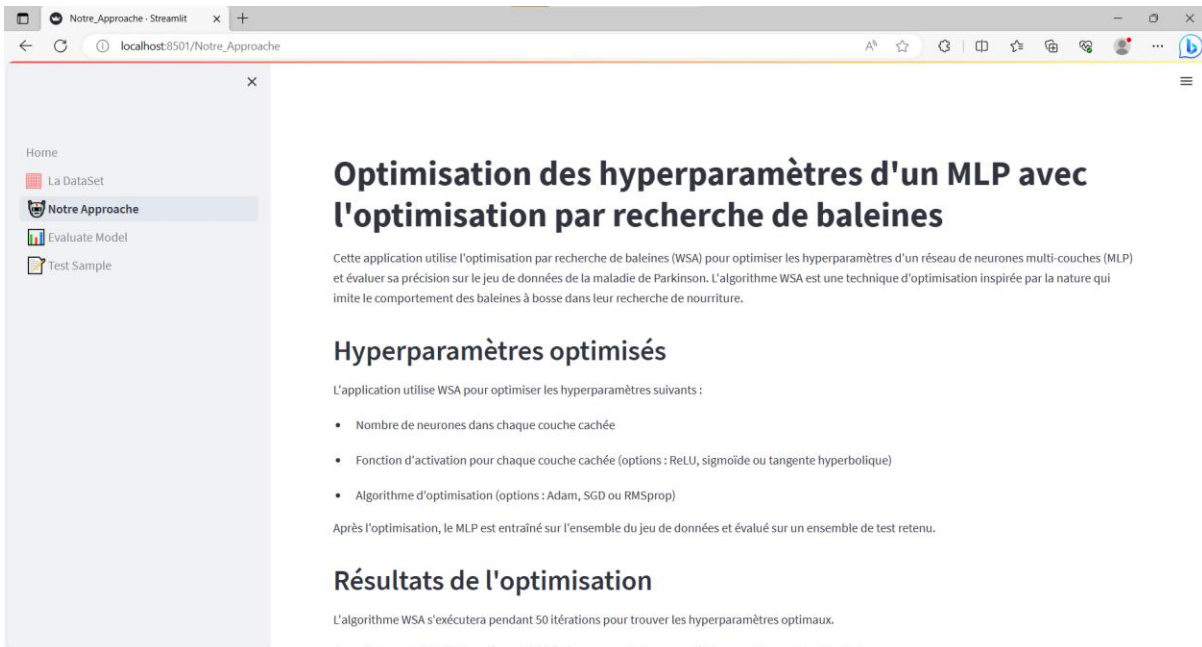


Figure 13 - Fenêtre de l'approche

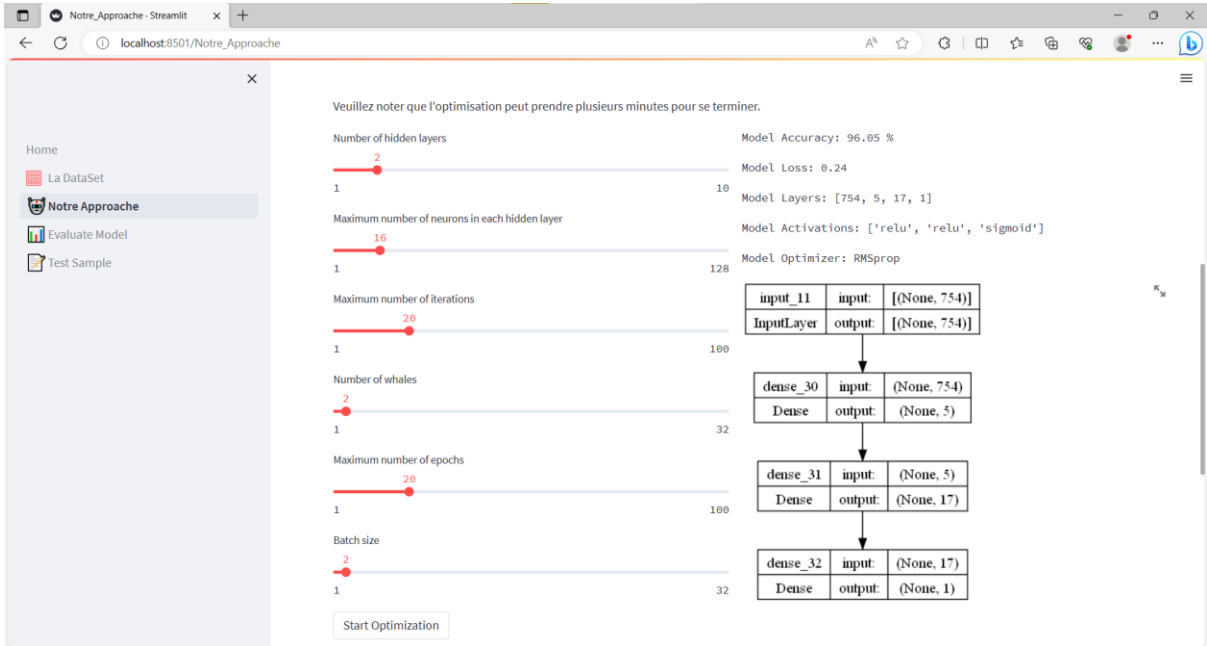


Figure 14 - Fenêtre d'exécution de la recherche WOA

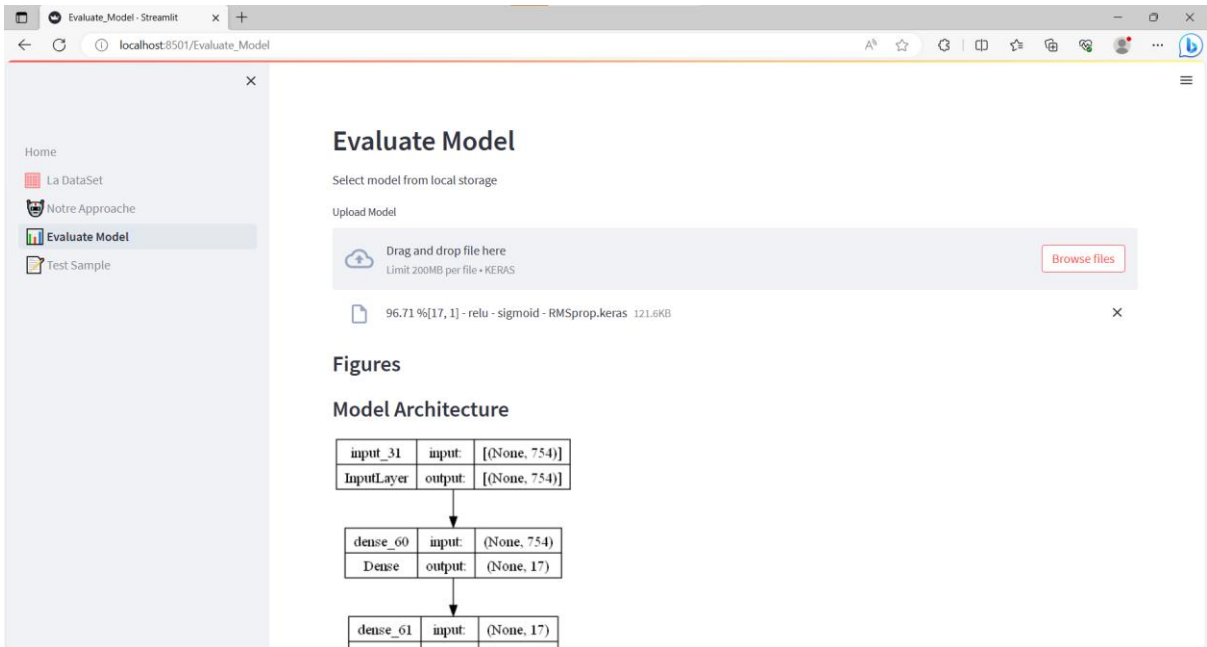


Figure 15 - Évaluation du modèle

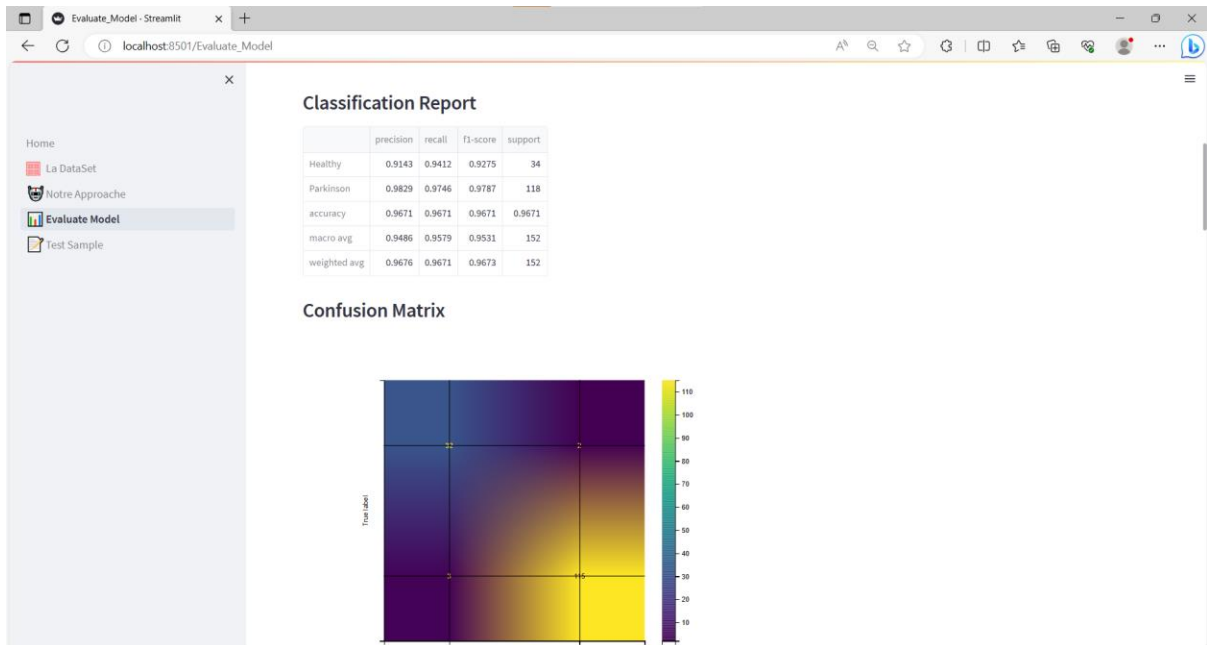


Figure 16 - Résultat de classification

4.11 Implications cliniques

Cette étude démontre le potentiel de l'intelligence artificielle et de l'apprentissage automatique pour la détection précoce de la maladie de Parkinson à partir de données vocales.

Le déploiement du modèle MLP optimisé par WOA en clinique pourrait constituer un outil d'aide au diagnostic rapide, non invasif et peu coûteux. En identifiant les patients à risque à un stade précoce, ce test peut initier un traitement et un suivi appropriés pour ralentir la progression de la maladie. Nous avons également remarqué qu'en utilisant notre approche, non seulement nous pouvons modéliser avec une grande précision, mais également des modèles de plus petite taille, ce qui peut nous permettre d'exécuter ces modèles sur du matériel à très faible performance, tel que le matériel qui existe déjà dans les hôpitaux, ou nous pouvons utiliser des appareils IOT connectés directement à la machine de diagnoses afin d'aider le médecin à obtenir un premier avis du modèle

Cependant, plusieurs problèmes doivent être résolus avant l'utilisation dans la pratique clinique :

- Validation du modèle sur des données patients plus larges et proposées
- Interprétabilité des prédictions du modèle sur les données collectées à partir de plusieurs machines

4.12 Conclusion

Les résultats obtenus dans ce chapitre démontrent l'efficacité de l'algorithme Whale Optimization Algorithm (WOA) pour optimiser les hyperparamètres d'un réseau de neurones MLP dans la détection précoce de la maladie de Parkinson.

Le modèle proposé a surpassé les performances des autres modèles de classification testés, offrant une grande précision et une faible probabilité de faux négatifs. Cela ouvre la voie à l'utilisation de l'intelligence artificielle pour le diagnostic précoce de la maladie de Parkinson. Cependant, d'autres études et validations cliniques sont nécessaires avant que ce modèle puisse être déployé dans la pratique médicale.

Conclusion Générale

En conclusion, cette étude a fourni un aperçu complet de la classification automatique et des réseaux de neurones artificiels. Le premier chapitre a introduit le concept d'apprentissage machine et ses algorithmes, suivi d'une exploration de l'état de l'art et d'une comparaison de différentes approches. Le deuxième chapitre s'est concentré sur les réseaux de neurones artificiels, en discutant de leur histoire, des modèles de neurones biologiques et artificiels, des fonctions d'activation et des différents types de réseaux. Les applications des réseaux de neurones artificiels dans la recherche sur la maladie de Parkinson ont également été présentées.

Le troisième chapitre a présenté l'approche proposée, qui combinait l'algorithme d'optimisation des baleines et le perceptron multicouche pour l'optimisation. La description de l'ensemble de données sur la maladie de Parkinson utilisé dans l'étude a également été fournie. Dans le quatrième chapitre, les résultats du modèle proposé ont été présentés, suivis d'une comparaison avec d'autres modèles et d'une analyse des résultats. Les implications cliniques des résultats ont été discutées, mettant en évidence les avantages potentiels dans le diagnostic et la prise en charge de la maladie de Parkinson.

Dans l'ensemble, cette recherche contribue au domaine de la classification automatique et démontre l'efficacité de la combinaison de l'algorithme d'optimisation des baleines et du perceptron multicouche pour la prédiction de la maladie de Parkinson. Les résultats de l'étude ouvrent de nouvelles possibilités d'utilisation des réseaux de neurones artificiels dans le domaine de la santé et soulignent l'importance des techniques d'apprentissage machine dans la recherche médicale et le diagnostic.

Bibliographie

- [1] S. Russell et P. Norvig, *Intelligence artificielle: Avec plus de 500 exercices*. Pearson Education France, 2010.
- [2] M. Pak et S. Kim, « A review of deep learning in image recognition », in *2017 4th International Conference on Computer Applications and Information Processing Technology (CAIPT)*, août 2017, p. 1-3. doi: 10.1109/CAIPT.2017.8320684.
- [3] J. Zhang et F. Sun, « Research on the Application of Computer Artificial Intelligence Machine Translation System in the Sci-tech Journals », in *2022 IEEE Asia-Pacific Conference on Image Processing, Electronics and Computers (IPEC)*, avr. 2022, p. 633-636. doi: 10.1109/IPEC54454.2022.9777421.
- [4] J. R. Almeida, E. Monteiro, L. B. Silva, A. Pazos Sierra, et J. L. Oliveira, « A Recommender System to Help Discovering Cohorts in Rare Diseases », in *2020 IEEE 33rd International Symposium on Computer-Based Medical Systems (CBMS)*, juill. 2020, p. 25-28. doi: 10.1109/CBMS49503.2020.00012.
- [5] J. N. Jothi, S. Poongodi, V. Chinnammal, L. Kannagi, M. Panneerselvam, et R. T. Prabu, « AI Based Humanoid Chatbot for Medical Application », in *2022 3rd International Conference on Smart Electronics and Communication (ICOSEC)*, oct. 2022, p. 1135-1140. doi: 10.1109/ICOSEC54921.2022.9951910.
- [6] S. Han et F. Cointault, « Détection précoce de maladies sur feuilles par traitement d'images », présenté à Orasis, Congrès des jeunes chercheurs en vision par ordinateur, juin 2013. Consulté le: 23 février 2023. [En ligne]. Disponible sur: <https://hal.science/hal-00829402>
- [7] Y. Kumar, A. Koul, R. Singla, et M. F. Ijaz, « Artificial intelligence in disease diagnosis: a systematic literature review, synthesizing framework and future research agenda », *J. Ambient Intell. Humaniz. Comput.*, vol. 14, n° 7, p. 8459-8486, 2023, doi: 10.1007/s12652-021-03612-z.
- [8] M. Ferdous, J. Debnath, et N. R. Chakraborty, « Machine Learning Algorithms in Healthcare: A Literature Survey », in *2020 11th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, juill. 2020, p. 1-6. doi: 10.1109/ICCCNT49239.2020.9225642.
- [9] M. Ene, « Neural network-based approach to discriminate healthy people from those with Parkinson's disease », *Ann. Univ. Craiova - Math. Comput. Sci. Ser.*, 2008, Consulté le: 23 février 2023. [En ligne]. Disponible sur: <https://www.semanticscholar.org/paper/Neural-network-based-approach-to-discriminate-from-Ene/c1e09591ced9acc4f6d0062eb8911cc2fb3167d7>

- [10] F. Åström et R. Koker, « A parallel neural network approach to prediction of Parkinson's Disease », *Expert Syst. Appl.*, vol. 38, n° 10, p. 12470-12474, sept. 2011, doi: 10.1016/j.eswa.2011.04.028.
- [11] S. A. Mostafa *et al.*, « Examining multiple feature evaluation and classification methods for improving the diagnosis of Parkinson's disease », *Cogn. Syst. Res.*, vol. 54, p. 90-99, mai 2019, doi: 10.1016/j.cogsys.2018.12.004.
- [12] S. Aich, H.-C. Kim, K. younga, K. L. Hui, A. A. Al-Absi, et M. Sain, « A Supervised Machine Learning Approach using Different Feature Selection Techniques on Voice Datasets for Prediction of Parkinson's Disease », *2019 21st Int. Conf. Adv. Commun. Technol. ICACT*, p. 1116-1121, févr. 2019, doi: 10.23919/ICACT.2019.8701961.
- [13] M. A. Little *et al.*, P. E. McSharry, E. J. Hunter, J. Spielman, et L. O. Ramig, « Suitability of Dysphonia Measurements for Telemonitoring of Parkinson's Disease », *IEEE Trans. Biomed. Eng.*, vol. 56, n° 4, p. 1015-1022, avr. 2009, doi: 10.1109/TBME.2008.2005954.
- [14] L. A. Passos *et al.*, « Parkinson Disease Identification Using Residual Networks and Optimum-Path Forest », *2018 IEEE 12th Int. Symp. Appl. Comput. Intell. Inform. SACI*, p. 000325-000330, mai 2018, doi: 10.1109/SACI.2018.8441012.
- [15] G. Palm, « Warren McCulloch and Walter Pitts: A Logical Calculus of the Ideas Immanent in Nervous Activity », G. Palm et A. Aertsen, Éd., Berlin, Heidelberg: Springer Berlin Heidelberg, 1986, p. 229-230. doi: 10.1007/978-3-642-70911-1_14.
- [16] J. J. McCarthy *et al.*, « Artificial Intelligence », Research Laboratory of Electronics (RLE) at the Massachusetts Institute of Technology (MIT), Technical Report, janv. 1960. Consulté le: 23 février 2023. [En ligne]. Disponible sur: <https://dspace.mit.edu/handle/1721.1/53375>
- [17] D. E. Rumelhart, G. E. Hinton, et R. J. Williams, « Learning representations by back-propagating errors », *Nature*, vol. 323, n° 6088, Art. n° 6088, oct. 1986, doi: 10.1038/323533a0.
- [18] Y. Lecun, L. Bottou, Y. Bengio, et P. Haffner, « Gradient-based learning applied to document recognition », *Proc. IEEE*, vol. 86, n° 11, p. 2278-2324, nov. 1998, doi: 10.1109/5.726791.
- [19] C. Janiesch, P. Zschech, et K. Heinrich, « Machine learning and deep learning », *Electron. Mark.*, vol. 31, n° 3, p. 685-695, sept. 2021, doi: 10.1007/s12525-021-00475-2.
- [20] C. Touzet, « LES RESEAUX DE NEURONES ARTIFICIELS, INTRODUCTION AU CONNEXIONNISME », 1992. Consulté le: 23 février 2023. [En ligne]. Disponible sur: <https://www.semanticscholar.org/paper/LES-RESEAUX-DE-NEURONES-ARTIFICIELS%2C-INTRODUCTION-Touzet/2dff2a84267fc353b16904fed8bfde01a2e95d48>
- [21] C. Y. Fook, M. Hariharan, S. Yaacob, et A. Adom, « A review: Malay speech recognition and audio visual speech recognition », in *2012 International Conference on Biomedical Engineering (ICoBE)*, févr. 2012, p. 479-484. doi: 10.1109/ICoBE.2012.6179063.
- [22] H. Grisstte et E. Nfaoui, « Daily life patients Sentiment Analysis model based on well-encoded embedding vocabulary for related-medication text », in *2019 IEEE/ACM*

- International Conference on Advances in Social Networks Analysis and Mining (ASONAM)*, août 2019, p. 921-928. doi: 10.1145/3341161.3343854.
- [23] R. Schönweiler, M. Hess, P. Wübbelt, et M. Ptok, « Novel approach to acoustical voice analysis using artificial neural networks », *J. Assoc. Res. Otolaryngol. JARO*, vol. 1, n° 4, p. 270-282, déc. 2000, doi: 10.1007/s101620010020.
- [24] P. D. Acton et A. Newberg, « Artificial neural network classifier for the diagnosis of Parkinson's disease using [99mTc]TRODAT-1 and SPECT », *Phys. Med. Biol.*, vol. 51, n° 12, p. 3057, mai 2006, doi: 10.1088/0031-9155/51/12/004.
- [25] R. M. Sadek *et al.*, « Parkinson's Disease Prediction Using Artificial Neural Network », 2019, Consulté le: 23 février 2023. [En ligne]. Disponible sur: <http://dspace.alazhar.edu.ps/xmlui/handle/123456789/302>
- [26] D. Gil et M. JOHNSON, « Diagnosing Parkinson by using Artificial Neural Networks and Support Vector Machines », vol. 9, janv. 2009.
- [27] S. Mirjalili et A. Lewis, « The Whale Optimization Algorithm », *Adv. Eng. Softw.*, vol. 95, p. 51-67, mai 2016, doi: 10.1016/j.advengsoft.2016.01.008.
- [28] « Multilayer Perceptron - an overview | ScienceDirect Topics ». <https://www.sciencedirect.com/topics/computer-science/multilayer-perceptron> (consulté le 15 avril 2023).
- [29] C. O. Sakar *et al.*, « A comparative analysis of speech signal processing algorithms for Parkinson's disease classification and the use of the tunable Q-factor wavelet transform », *Appl. Soft Comput.*, vol. 74, p. 255-263, janv. 2019, doi: 10.1016/j.asoc.2018.10.022.
- [30] G. Ke *et al.*, « LightGBM: A Highly Efficient Gradient Boosting Decision Tree », présenté à Advances in Neural Information Processing Systems 30 (NIP 2017), déc. 2017. Consulté le: 3 août 2023. [En ligne]. Disponible sur: <https://www.microsoft.com/en-us/research/publication/lightgbm-a-highly-efficient-gradient-boosting-decision-tree/>
- [31] H. Liang, K. Jiang, T.-A. Yan, et G.-H. Chen, « XGBoost: An Optimal Machine Learning Model with Just Structural Features to Discover MOF Adsorbents of Xe/Kr », *ACS Omega*, vol. 6, n° 13, p. 9066-9076, avr. 2021, doi: 10.1021/acsomega.1c00100.
- [32] F. Pedregosa *et al.*, « Scikit-learn: Machine Learning in Python ». arXiv, 5 juin 2018. doi: 10.48550/arXiv.1201.0490.