

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

Université Mohamed El-Bachir El-Ibrahimi – Bordj Bou Arréridj

Faculté des Sciences et de la Technologie

Département d'Électronique

Mémoire

Présenté en vue de l'obtention du

DIPLÔME DE MASTER

Filière : Télécommunication

Spécialité: Systèmes de Télécommunications

Par :

Gherbi Hani

Ali Mehenni Djamila

Intitulé :

*Analyse du signal vocal pour le diagnostic de la maladie de Parkinson basé
sur les modèles de Markov cachés HMM*

Soutenu le : 01/07/2025

Devant le jury composé de :

<i>Nom et Prénom</i>	<i>Grade</i>	<i>Qualité</i>	<i>Établissement</i>
Mme. Adoui Ibtissem	MCA	Président	Univ-BBA
Mr. Asbai Nassim	MCA	Examiner	Univ-BBA
Mr. Hacine Gharbi Abdenour	MCA	Encadreur	Univ-BBA

Année universitaire 2024/2025



Remerciements



C'est avec une profonde gratitude et une immense reconnaissance que nous remercions tout d'abord Allah Tout-Puissant, pour nous avoir accordé la santé, la force et la patience nécessaires à l'aboutissement de ce travail. Sa guidance et Son soutien tout au long de nos années d'études ont été la lumière qui nous a permis de surmonter chaque épreuve.

*Nous adressons nos sincères remerciements à notre encadreur, Monsieur le **Dr. HACINE GHARBI ABDENOUR**, pour ses efforts, ses conseils et son accompagnement constant. Il nous a offert la liberté et la confiance nécessaires pour mener à bien ce mémoire, et ses remarques pertinentes ont été essentielles à notre réussite.*

Nous exprimons également notre profonde gratitude aux membres du jury, pour le temps qu'ils nous ont consacré, ainsi que pour leurs observations et suggestions enrichissantes qui contribueront à l'amélioration de notre travail.

Nos remerciements vont également à tous les enseignants qui nous ont accompagnés et soutenus tout au long de notre parcours universitaire.

Nous tenons en outre à remercier chaleureusement nos amis, pour leur soutien, direct ou indirect.

Aucun mot ne saurait exprimer pleinement notre reconnaissance envers toutes les personnes qui ont contribué, de près ou de loin, à notre cheminement académique. Merci à vous tous du fond du cœur. Votre soutien et vos encouragements ont rendu cette réussite possible



Dédicace

*À mes grands-parents,
Que Dieu repose leurs âmes en paix.*

*À mes parents,
Votre amour inconditionnel et vos innombrables sacrifices ont
été la pierre angulaire de mon parcours. Je vous suis
éternellement reconnaissant pour votre soutien indéfectible et
vos sages conseils.*

*À mes sœurs, et À mon frère
Vous avez été mes piliers, mes compagnes fidèles dans les
hauts et les bas de la vie. Votre amour et votre soutien ont
toujours été une source d'inspiration pour moi.*

*À mes amis,
Votre amitié et votre camaraderie ont été pour moi une
véritable source de joie et de force. Merci d'avoir été présents
dans les bons comme dans les mauvais moments.
Un remerciement tout particulier à mon binôme de
travail,¹ *Ali Mehenni Djamila*, Votre collaboration et votre
engagement ont été essentiels à nos réussites communes.*

*En conclusion,
Je remercie Dieu Tout-Puissant pour Ses bénédictions et Sa
guidance. J'adresse ma profonde gratitude à toutes les
personnes qui ont contribué, de près ou de loin, à mon
cheminement — famille, amis ou collègues. Votre soutien a été
inestimable, et je suis profondément reconnaissant envers
chacun d'entre vous.*

GHERBI Hani



Dédicace

بسم الله الرحمن الرحيم

(قل اعملوا فسيرى الله عملكم ورسوله و المؤمنين)

"اهدي تخرجي الى تلك المرأة العظيمة جدتي رحمها الله لطالما تمنيت ان تقر عينها برؤيتي في يوم كهذا
فرحتي ينقصها وجودك ونجاحي ينقصه فخرك بي"

À mes parents,

Votre amour inconditionnel et vos innombrables sacrifices ont été la pierre angulaire de mon parcours. Je vous suis éternellement reconnaissant pour votre soutien indéfectible et vos sages conseils.

À mes sœurs, et À mes frères

Vous avez été mes piliers, mes compagnes fidèles dans les hauts et les bas de la vie. Votre amour et votre soutien ont toujours été une source d'inspiration pour moi.

À mes amis,

*Votre amitié et votre camaraderie ont été pour moi une véritable source de joie et de force. Merci d'avoir été présents dans les bons comme dans les mauvais moments.
Un remerciement tout particulier à mon binôme de travail, *Gharbí Haní*, Votre collaboration et votre engagement ont été essentiels à nos réussites communes.*

En conclusion,

Je remercie Dieu Tout-Puissant pour Ses bénédictions et Sa guidance. J'adresse ma profonde gratitude à toutes les personnes qui ont contribué, de près ou de loin, à mon cheminement — famille, amis ou collègues. Votre soutien a été inestimable, et je suis profondément reconnaissant envers chacun d'entre vous.

Ali Mehenni Djamila

Table des matières

Remerciements

Dédicace

Dédicace

Liste des Figures

Liste des Tableaux

Liste des Equations

Acronymes et Abbreviations

Abstract

المخلص

Résumé

Introduction Générale.....	3
Chapitre 1 Généralités sur le Diagnostic de la Maladie de Parkinson.....	6
1.1 Introduction	7
1.2 Maladie de Parkinson	7
1.2.1 Définition et Historique	7
1.2.2 Symptômes de Parkinson	8
1.2.2.1 Tremblement de Repos.....	8
1.2.2.2 L'akinésie et la bradykinésie.....	8
1.2.2.3 La rigidité	8
1.2.2.4 L'instabilité posturale.....	8
1.2.3 Évolution de la maladie de Parkinson	9
1.2.4 Méthodes de diagnostic de la maladie de Parkinson.....	9
1.2.4.1 Diagnostic radiologique	9
1.2.4.2 Diagnostic biologique	10
1.3 Modalités de diagnostic de la maladie Parkinson	11
1.3.1 Ecriture manuscrite	11
1.3.2 L'électroencéphalogramme (EEG)	12
1.3.3 L'accélérométrie	12
1.3.4 Electromyographiques (EMG)	12
1.3.5 Voix.....	12
1.4 Fonctionnement d'un système de diagnostic de la maladie de Parkinson	13
1.5 Méthodes de classification	14
1.5.1 Classificateur GMM.....	14
1.5.2 Classificateur HMM.....	15
1.5.2.1 Modèles de Markov cachés	15
1.5.2.2 Définition chaîne de Markov.....	16
1.5.2.3 Fonctionnalités d'un HMM.....	17
1.6 État de l'art sur les systèmes de diagnostic de la maladie de Parkinson.....	17
1.7 Exemple d'un système de diagnostic de la MP utilisant la modalité EMG	19
1.8 Conclusion.....	20
Chapitre 2 Système de Diagnostic de la Maladie de Parkinson basé sur l'analyse de la	
2.1 Introduction	22
2.2 Définition du signal parole	22
2.3 Caractéristiques du signal de parole	22

2.4 2.4 Traitement de la parole.....	23
2.5 Systèmes de diagnostic de la MP proposés.....	23
2.5.1 Système de diagnostic de la MP basé sur le classificateur HMM.....	24
2.5.2 Système de diagnostic de la MP basé sur le classificateur GMM combiné avec la stratégie de la règle de vote	24
2.6 Extraction de paramètres.....	26
2.6.1 Coefficients cepstraux sur l'échelle Mel (MFCC).....	26
2.6.2 Étapes de calcul du vecteur de paramètres MFCC.....	26
2.6.2.1 Prétraitement du signal (La préaccentuation).....	27
2.6.2.2 Fenêtrage	27
2.6.2.3 La transformée de Fourier discrète.....	27
2.6.2.4 Banc de filtres à l'échelle Mel et Log	28
2.6.2.5 Transformée en cosinus discrète	29
2.6.2.6 Calcul des paramètres dynamiques des MFCC.....	30
2.6.3 Coefficients PLP (Perceptual Linear prediction PLP)	30
2.7 Conclusion.....	31
Chapitre 3 Implémentation du système de diagnostic de la maladie de parkinson basé sur l'analyse de la voix et les modèles HMM	32
3.1 Introduction	33
3.2 Description de la base de données Italian-Parkinson's Voice And Speech	34
3.2.1 Répartition de la base de données en mode Indépendant.....	35
3.2.2 Répartition de la base de données en mode Dépendant	37
3.3 Implémentation du système basé sur les modèles HMM.....	37
3.3.1 Phase d'apprentissage	37
3.3.1.1 Extraction des paramètres	37
3.3.1.2 Outils d'apprentissage	39
3.3.1.2.1 L'initialisation des modèles HMM	39
3.3.1.2.2 Réestimation des modèles HMM	41
3.3.1.2.3 L'augmentation de nombre de gaussiennes	43
3.3.2 Définition du dictionnaire et du modèle du Langage.....	44
3.3.3 Classification.....	44
3.3.4 Évaluation du système de reconnaissance.....	45
3.4 Critères d'évaluation	46
3.5 Expérience et résultats.....	46
3.5.1 Expérience 1: performances du système basé sur le descripteur MFCC en mode indépendant	46
3.5.2 Expérience 2: Performances du système basé sur le descripteur MFCC en mode dépendant	47
3.5.3 Expérience 3: Performances du système basé sur le descripteur PLP en mode indépendant	48
3.5.4 Expérience 4 : Performances du système basé sur le descripteur PLP en mode dépendant	49
3.5.5 Expérience 5: Système de diagnostic de la maladie de Parkinson basé sur le classificateur GMM en mode indépendant.....	50
3.5.6 Expérience 6 : Système de diagnostic de la maladie de Parkinson basé sur le classificateur GMM en mode dépendant.....	51
3.5.7 Système de diagnostic de la maladie de Parkinson basé sur le classificateur GMM en mode indépendant avec le descripteur PLP.....	53
3.5.8 Système de diagnostic de la maladie de Parkinson basé sur le classificateur GMM en mode dépendant avec le descripteur PLP.....	54

3.6 Conclusion.....	55
Conclusion Générale	56
REFERENCES	

Liste des Figures

Figure 1.1 : Architecture d'un système de diagnostic de la maladie de Parkinson.....	14
Figure 1.2 : Schéma fonctionnel du système de classification	19
Figure 2.1 : Fonctions du traitement de la parole	23
Figure 2.2 : Schéma du système diagnostique de la MP basé sur le classificateur HMM.....	24
Figure 2.3 : Schéma du système diagnostique basé sur le classificateur GMM	25
Figure 2.4 : Schéma fonctionnel des étapes de calcul des coefficients MFCC.....	26
Figure 2.5 : Relation entre la fréquence en Hertz et en échelle Mel.	28
Figure 2.6 : Les caractéristiques statiques MFCC	29
Figure 2.7 : Les caractéristiques statiques et dynamiques.	30
Figure 2.8 : Schéma fonctionnel du traitement PLP	31
Figure 2.9 : Calcul des paramètres PLP	31
Figure 3.1 : le fichier texte liste.wav2mfc.....	38
Figure 3.2 : les vecteurs MFCC résultant.....	38
Figure 3.3 : fichier proto pour un modèle HMM à 5 états avec des vecteurs de 39 dimensions ..	40
Figure 3.4 : fichier de configuration ' conf_user '	40
Figure 3.5 : fichier trainlist.....	40
Figure 3.6 : les fichiers résultant après l'exécution du command HcompV	41
Figure 3.7 : illustration du fichier trainmlf.....	42
Figure 3.8 : illustration du fichier "liste_models"	42
Figure 3.9 : illustration du fichier hmmdef	42
Figure 3.10 : illustration du fichier macro.....	43
Figure 3.11 : illustration du fichier silhed1	43
Figure 3.12 : Illustration du fichier gramme	44
Figure 3.13 ; Illustration du fichier dictionnaire	45
Figure 3.14 : Résultat de la deuxième expérience en choisissant un nombre d'état égal 4 et un nombre de gaussiennes égal à 8	47
Figure 3.15 : Résultat de la deuxième expérience en choisissant un nombre d'état égal 7 et un nombre de gaussiennes égal à 32	47
Figure 3.16 : La figure , affiche les détails des performances du système en choisissant un nombre d'état égal à 10 et un nombre de gaussiennes égal à .32.....	48
Figure 3.17 : La figure affiche les détails des performances du système en choisissant un nombre d'état égal à 7 et un nombre de gaussiennes égal à .32.....	49
Figure 3.18 : Taux TCV pour classificateur GMM en mode indépendant.....	50
Figure 3.19 : Taux TCS pour classificateur GMM en mode indépendant	50
Figure 3.20 : Taux TCV pour classificateur GMM en mode dépendant.....	51
Figure 3.21 : Taux TCS pour classificateur GMM en mode dépendant.....	52
Figure 1.21 : Taux TCV pour classificateur GMM en mode indépendant <i>avec le descripteur PLP</i>	53
Figure 1.22 : Taux TCS pour classificateur GMM en mode indépendant <i>avec le descripteur PLP</i>	53
Figure 1.23 : Taux TCV pour classificateur GMM en mode dépendant <i>avec le descripteur PLP</i>	54

Figure 1.24 : Taux TCV pour classificateur GMM en mode dépendant *avec le descripteur*

PLP.....54

Liste des Tableaux

Tableau 1.1 : Techniques Radiologiques utilisées dans le Diagnostic de la MP	10
Tableau 1.2 : Techniques biologiques utilisées dans le diagnostic de la MP	11
Tableau 1.3 : Les recherches sur le diagnostic de la maladie de Parkinson basé sur l'analyse de la voix.....	18
Tableau 3.1 : Groupe des personnes saines.....	34
Tableau 3.2 : Groupe des personnes parkinsoniens	35
Tableau 3.3 : Répartition des signaux des locuteurs NP dans la base d'apprentissage, en mode indépendant.	36
Tableau 3.4 : Répartition des signaux des locuteurs NP dans la base de test, en mode indépendant	36
Tableau 3.5 : Répartition des signaux des locuteurs P dans la base d'apprentissage, en mode indépendant	36
Tableau 3.6 : Répartition des signaux des locuteurs P dans la base de test, , en mode indépendant	36
Tableau 3.7 : Répartition au mode indépendant des signaux en base d'apprentissage et base de test	37
Tableau 3.8 : Répartition au mode dépendant des signaux en base d'apprentissage et base de test	37
Tableau 3.9 : Influence du nombre d'états HMM et de gaussiennes GMM sur les performances du système basé sur le descripteur MFCC en mode indépendant.	47
Tableau 3.10 : Taux TR pour différentes valeurs de Nbr d'état et de Nbr de gaussiennes optimales	48
Tableau 3.11 : Influence du nombre d'états HMM et du nombre de gaussiennes sur la performance du système _PLP en mode indépendante	49
Tableau 3.12 : Influence du nombre d'états HMM et de gaussiennes sur la performance du système _PLP en mode dépendante	49

Acronymes et Abréviations

AI	Artificial Intelligence
ANN	Artificial Neural Network
APP	Apprentissage (Training Set)
CNN	Convolutional Neural Network
DCT	Discrete Cosine Transform
DFT	Discrete Fourier Transform
DWE	Discrete Wavelet Energy
DWT	Discrete Wavelet Transform
EEG	Electroencephalography
EM	Expectation-Maximization
EMG	Electromyogram
FFT	Fast Fourier Transform
F₀ (F0)	Fundamental Frequency
GMM	Gaussian Mixture Model
HERest	HTK Re-estimator Tool
HHed	HTK HMM Editor
HMM	Hidden Markov Model
HParse	HTK Parser
HRest	HTK Re-estimator
HTK	Hidden Markov Model Toolkit
HVite	HTK Viterbi Decoder
IDCT	Inverse Discrete Cosine Transform
IDFT	Inverse Discrete Fourier Transform
LCR	Liquide Céphalo-Rachidien
LPCC	Linear Predictive Cepstral Coefficients
LPC	Linear Predictive Coding
LRRK2	Leucine Rich Repeat Kinase 2
LWE	Logarithmic Wavelet Energy
MFCC	Mel-Frequency Cepstral Coefficients
MIBG	Meta-Iodo Benzyl Guanidine
MP	Maladie de Parkinson
NP	Non-Parkinsonian
MLP	Multi-Layer Perceptron
MP	Maladie de Parkinson
NP	Non-Parkinsonian
NURR1	Nuclear Receptor Related 1
PD	Parkinson's Disease
PET	Positron Emission Tomography
PLP	Perceptual Linear Prediction
PPE	Pitch Period Entropy

SVM	Support Vector Machine
WCC	Wavelet Cepstral Coefficients

Abstract

The early diagnosis of Parkinson's disease (PD) represents a major challenge in healthcare. In this work, we developed an intelligent system based on voice signal analysis for diagnosing this pathology. Acoustic parameters such as MFCC and PLP coefficients were extracted and then classified using the HMM (Hidden Markov Model) classifier. The system's performance was evaluated using the IPVS (Italian Parkinson's Voice and Speech) database. These results were compared with those of another diagnostic system for PD based on the GMM (Gaussian Mixture Model) classifier combined with a voting rule strategy. The experimental results showed high recognition rates, reaching 100% in the speaker-dependent mode for both systems. In the speaker-independent mode, the rate reached 90.21% in the first system using the PLP descriptor, and 97.17% in the second system using the MFCC descriptor. These results demonstrate the effectiveness of the second system based on the MFCC descriptor in the speaker-independent mode. Such performance confirms the potential of voice analysis as a helpful tool in the diagnosis of Parkinson's disease.

Keywords: Parkinson's disease, voice signal, MFCC, PLP, HMM, GMM, IPVS database.

الملخص

يمثل التشخيص المبكر لمرض باركنسون (MP) تحدياً كبيراً في المجال الصحي. في هذا العمل، قمنا بتطوير نظام ذكي يعتمد على تحليل الإشارة الصوتية لتشخيص هذا المرض. تم استخراج معلمات صوتية مثل معاملات MFCC و PLP، ثم تصنيفها باستخدام المصنف (HMM نموذج ماركوف المخفي).

تم تقييم أداء النظام باستخدام قاعدة البيانات IPVS (Italian Parkinson's Voice and Speech). كما تم مقارنة هذه الأداءات مع نظام تشخيص آخر لمرض باركنسون يعتمد على المصنف (GMM نموذج المزيج الغاوسي) مدمجاً مع إستراتيجية قاعدة التصويت. أظهرت النتائج التجريبية معدلات تعرف مرتفعة، حيث بلغت 100% في الوضع المعتمد على المتكلم بالنسبة لكلا النظامين. أما في الوضع غير المعتمد على المتكلم، فقد بلغت النسبة 90.21% في النظام الأول باستخدام الوصف PLP، و 97.17% في النظام الثاني باستخدام الوصف MFCC.

تُظهر هذه النتائج فعالية النظام الثاني المبني على الوصف MFCC في الوضع غير المعتمد على المتكلم. وتؤكد هذه الأداءات إمكانيات تحليل الصوت كأداة مساعدة في تشخيص مرض باركنسون.

الكلمات المفتاحية: مرض باركنسون، الإشارة الصوتية، MFCC، PLP، HMM، GMM، قاعدة بيانات IPVS.

Résumé

Le diagnostic précoce de la maladie de Parkinson (MP) représente un enjeu majeur en santé. Dans ce travail, nous avons développé un système intelligent basé sur l'analyse du signal vocal pour le diagnostic de cette pathologie. Des paramètres acoustiques tels que les coefficients MFCC et PLP ont été extraits, puis classés à l'aide du classificateur HMM (Hidden Markov Model). Les performances du système sont évaluées sur la base de données IPVS (Italian Parkinson's Voice and Speech). Ces performances sont comparées avec celles d'un système de diagnostic de MP basé sur le classificateur GMM (Gaussian Mixture Model) combiné avec la stratégie de la règle de vote. Les résultats expérimentaux ont montré des taux de reconnaissance élevés, atteignant 100 % dans le mode dépendant du locuteur pour les deux systèmes. Alors, dans le mode indépendant, le taux atteint 90,21 % dans le premier système en utilisant le descripteur PLP, et atteint 97.17 % dans le deuxième système en utilisant le descripteur MFCC. Ainsi, ces

résultats montrent efficacité du deuxième système basé sur le descripteur MFCC dans le mode indépendant. Ces performances confirment le potentiel de l'analyse vocale comme outil d'aide au diagnostic de la maladie de Parkinson.

Mots-clés : Maladie de Parkinson, signal vocal, MFCC, PLP, HMM, GMM, Base IPVS.

Introduction Générale

Introduction Générale

La maladie de Parkinson (MP) est l'une des pathologies neurodégénératives les plus répandues dans le monde, touchant principalement les personnes âgées. Elle se manifeste par des troubles moteurs progressifs, tels que le tremblement de repos, la rigidité, la bradykinésie, et l'instabilité posturale, qui compromettent la qualité de vie des patients [1]. Décrite pour la première fois en 1817 par James Parkinson [3][2], cette maladie est aujourd'hui au centre de nombreuses recherches en neurologie et en sciences du vivant.

Le diagnostic de la MP repose principalement sur une évaluation clinique, car il n'existe pas encore de test biologique ou d'imagerie permettant de confirmer la maladie avec certitude à ses débuts. Or, un diagnostic précoce est essentiel pour ralentir sa progression et améliorer la prise en charge des patients. Face à cette difficulté, les chercheurs se tournent vers des approches alternatives basées sur l'analyse de données biomédicales, telles que l'écriture manuscrite, l'EEG, l'ECG, la marche, ou encore la voix [4].

L'analyse vocale, en particulier, a suscité un intérêt croissant en raison de son caractère non invasif, peu coûteux et facilement reproductible. Des études ont montré que près de 90 % des patients présentent des troubles vocaux aux premiers stades de la maladie, ce qui en fait un biomarqueur prometteur pour un diagnostic anticipé [4]. L'exploitation de paramètres acoustiques tels que les coefficients MFCC, PLP, LPCC et LPC associée à des algorithmes d'apprentissage automatique, ouvre la voie à la conception de systèmes intelligents capables de détecter la maladie à partir d'un simple enregistrement vocal [5].

Dans ce contexte, notre travail consiste à développer un système de diagnostic automatique de la maladie de Parkinson basé sur l'analyse de la voix, en utilisant les modèles statistiques HMM (modèles de Markov cachés) [6], fonctionnant en modes dépendant et indépendant. De plus, nous proposons, un autre système basé sur les modèles GMM combinés avec la stratégie de la règle de vote pour mieux valider l'efficacité de l'analyse de la voix pour la tâche de diagnostic de la MP avec différents classificateurs. Dans notre travail, nous utilisons les descripteurs MFCC et PLP pour l'étape d'extraction de paramètres. Ce mémoire est structuré en trois chapitres, chacun abordant une étape clé du développement de notre système :

- **Dans le chapitre 1**, nous présentons une vue d'ensemble de la maladie de Parkinson : ses origines, ses symptômes, ses différentes formes cliniques, ainsi que les méthodes traditionnelles et modernes utilisées pour son diagnostic, y compris l'imagerie médicale, les tests biologiques et les approches basées sur les signaux physiologiques. Nous

décrivons brièvement un système de diagnostic de la MP basé sur l'extraction des paramètres à partir des signaux EMG, combinée avec le classificateur ANN et la stratégie de la règle de vote.

- **Dans le chapitre 2**, nous abordons les principes de l'analyse vocale appliquée au diagnostic médical. Nous détaillons les caractéristiques acoustiques pertinentes pour détecter la maladie, ainsi que les techniques de traitement du signal utilisées, notamment les coefficients MFCC, PLP. Nous présentons la conception de deux systèmes de diagnostic basé sur respectivement sur les modèles HMM, et GMM, combinés avec l'extraction des paramètres MFCC et PLP. Nous décrivons les étapes clés des systèmes, depuis l'acquisition des signaux vocaux jusqu'à leur classification, en passant par l'extraction des paramètres et l'entraînement des modèles.
- **Dans le chapitre 3**, nous exposons l'implémentation des deux systèmes proposés ainsi que les résultats expérimentaux obtenus à partir de la base de données IPVS (*Italian Parkinson's Voice and Speech*). Nous évaluons les performances de nos systèmes selon différents modes (locuteur dépendant, indépendant) et analysons l'impact des paramètres des modèles HMM tels que le nombre d'états et le nombre de gaussiennes sur la précision du premier système et également l'impact du nombre de gaussiennes des modèles GMM concernant le deuxième système.
- **Enfin**, nous concluons notre travail avec des discussions, des limitations rencontrées, des perspectives et des pistes d'amélioration futures.

Chapitre 1

Généralités sur le Diagnostic de la Maladie de Parkinson

1.1 Introduction

Le cerveau est l'organe le plus complexe du corps humain, contenant des milliards de neurones qui fonctionnent en parfaite harmonie pour nous permettre de penser, d'analyser et de contrôler diverses fonctions corporelles. Il est le centre de l'intelligence, de la perception, des émotions, du mouvement et de la communication. Toute perturbation dans la communication entre ces cellules peut entraîner des troubles à grande échelle, affectant de nombreux aspects de la vie quotidienne. Parmi les maladies qui affectent le cerveau, on peut citer : les maladies neuro-dégénératives qui occupent une place prépondérante en raison de leurs complexités et de leurs gravités.

Ce terme désigne un ensemble de troubles qui entraînent progressivement la mort des cellules nerveuses, provoquant une détérioration fonctionnelle irréversible. Ces maladies incluent la maladie d'Alzheimer, qui affecte la mémoire et la cognition, ainsi que la maladie de Parkinson, l'un des troubles neurologiques les plus répandus, affectant principalement le système moteur. La maladie de Parkinson se manifeste par un ensemble de symptômes caractéristiques, notamment des tremblements, une rigidité musculaire, une lenteur des mouvements et des troubles de l'équilibre et de la marche. Malgré les avancées significatives dans la recherche en neurosciences, les causes exactes de cette maladie restent encore inconnues, ce qui représente un défi majeur pour les scientifiques dans le développement des systèmes de diagnostic efficace et fiable pour cette maladie. Cette maladie progresse de façon cachée, ce qui rend son étude particulièrement difficile.

Dans ce chapitre, nous présentons brièvement la maladie de Parkinson commençant par sa définition et son historique, en passant par ses symptômes et son impact sur la vie des patients, jusqu'aux méthodes les plus récentes d'évaluation et de diagnostic. Nous aborderons également l'impact de la maladie sur la voix, considéré comme l'un des modalités les plus importantes.

1.2 Maladie de Parkinson

1.2.1 Définition et Historique

La maladie de Parkinson est une affection neuro-dégénérative décrite pour la première fois en 1817 par le médecin James Parkinson [2]. Elle se caractérise principalement par des troubles du mouvement et une perte de contrôle moteur, causés par la dégénérescence des neurones situés dans une région du cerveau appelée substance noire.

Ces cellules sont responsables de la production de dopamine, un neurotransmetteur essentiel à la régulation des mouvements. Malgré la précision avec laquelle James Parkinson a décrit les manifestations cliniques de la maladie à son époque, aucun traitement efficace n'était alors disponible pour soulager les patients [3][4].

1.2.2 Symptômes de Parkinson

Les manifestations cliniques de la maladie de Parkinson reposent principalement par quatre signes cardinaux [1]:

1.2.2.1 Tremblement de Repos

Le tremblement de repos est généralement considéré comme le signe le plus connu de la maladie de Parkinson, chez environ 70 % des malades, Il est fréquemment identifié comme le symptôme initial.

Le tremblement se présente généralement d'unilatérale, d'un seul côté du corps, au niveau du pied ou de la main. Au fur et à mesure de la progression de la maladie, le tremblement peut finir par toucher les membres du côté opposé. Ce tremblement se distingue principalement par sa diminution lors de l'exécution de mouvements volontaires, ce qui permet de le différencier des autres types de tremblements.

1.2.2.2 L'akinésie et la bradykinésie

- L'akinésie et la bradykinésie sont des signes, qui cliniquement se définissent par une rareté (akinésie) et une lenteur (bradykinésie) des mouvements.
- Au niveau facial, on note une réduction de l'expressivité ainsi qu'une diminution de la fréquence de clignement des paupières.
- La voix peut devenir monotone et grave. On observe également des difficultés dans la réalisation des mouvements ainsi qu'une certaine lenteur dans leur exécution.

1.2.2.3 La rigidité

Il s'agit d'une élévation du tonus musculaire. Elle peut se traduire par une réduction du balancement du bras du côté du corps atteint par la maladie de Parkinson.

1.2.2.4 L'instabilité posturale

Il s'agit d'un symptôme tardif de la maladie de Parkinson, qui n'apparaît qu'après plusieurs années de progression. Elle se traduit par des troubles de l'équilibre, entraînant souvent des chutes.

1.2.3 Évolution de la maladie de Parkinson

La maladie de Parkinson étant causée par la perte progressive des neurones dopamine énergiques impliquée dans le contrôle des mouvements volontaires. Les patients consultent généralement pour des troubles moteurs.

Parmi les autres motifs de consultation sont signalés par les médecins liés à la maladie telle qu'il a diminution de la dextérité fine ou de la micrographie (écriture qui devient de plus en plus petit avec le temps. [\[1\]](#)

La maladie de Parkinson n'évolue pas de la même manière chez tous les patients, la progression peut s'étaler sur plusieurs décennies, alors que pour d'autres subissent une aggravation plus rapide. Les différents stades de progression de la maladie sont donnés comme suit, selon l'échelle de Hoehn et Yahr (1967) [\[1\]](#) :

- STADE 1 : Les symptômes sont unilatéraux et comprennent au moins deux des trois symptômes suivants: tremblement de repos, raideur et akinésie.
- STADE 2 : Les symptômes commencent à devenir bilatéraux et peuvent alors inclure des problèmes d'élocution, une posture déformée et des difficultés à marcher.
- STADE 3 : Les symptômes bilatéraux s'aggravent et des problèmes d'équilibre peuvent apparaître. L'autonomie de la personne n'est généralement pas affectée.
- STADE 4 : L'invalidité est présente, mais l'autonomie de la personne n'est généralement pas affectée. La bradykinésie est plus prononcée de même que les fluctuations, si elles sont présentes.
- STADE 5 : La personne est confinée à un fauteuil roulant ou doit rester alitée.

1.2.4 Méthodes de diagnostic de la maladie de Parkinson

Dans cette partie, nous allons présenter les principales méthodes utilisées pour diagnostiquer la maladie de Parkinson. Nous aborderons d'une part le diagnostic biologique, et d'autre part le diagnostic radiologique en mettant en évidence les outils et techniques propres à chacun

1.2.4.1 Diagnostic radiologique

La radiologie permet de poser un diagnostic plus rapide pour la maladie de Parkinson et de la distinguer des autres syndromes parkinsoniens. Les techniques utilisées sont résumés dans le tableau 1.1 [\[4\]](#):

Tableau 1.1 : Techniques Radiologiques utilisées dans le Diagnostic de la MP [4]

Méthodes	Biomarqueurs	Évaluations
TEMP (aussi appelée SPECT)	DAT SPECT	- Utile dans le diagnostic de la MP préclinique. - Inutile pour apprécier l'évolution.
TEMP (aussi appelée PET)	F-Fluorodopa et DAT PET	- Très sensible pour détecter la MP préclinique. - Trop cher et pourrait être affecté par la lévodopa.
Sonographie	Hyperéchogénicité de la substance noire (SN)	- Utile dans le diagnostic de la MP préclinique - Ne permet pas d'apprécier la progression de la maladie
IRM fonctionnelle (IRMf)	Fer dans la SN ; anisotropie fractionnelle	- Utile dans le diagnostic de la MP préclinique, surtout combinée avec des biomarqueurs cliniques. - D'autres études sont nécessaires.
Scintigraphie	MIBG	- Utile dans le diagnostic préclinique de la MP. - Manque de sensibilité.

Quelques spécifications Médicales sont données comme suit:

- Transporteur de la dopamine (DAT).
- Imagerie par Résonance Magnétique (IRM).
- Imagerie par Résonance Magnétique Fonctionnelle (IRMf).
- Méta-Iodo Benzyl Guanidine (MIBG).
- Tomographie par Émission de Positons (TEP).
- Substantia Nigra (SN).

Tomographie d'Émission mono photonique (TEMPS)

1.2.4.2 Diagnostic biologique

Le diagnostic biologique s'appuie sur l'identification de substance dont les concentrations habituellement constantes sont modifiées au cours de l'évaluation de la maladie de Parkinson. Les techniques utilisées se basent sur la génomique, transcriptomique, proteomique, métabolomique. Les prélèvements utilisés ainsi que leur utilisation sont résumés dans le Tableau 1.2. [4]

Tableau 1.2 : Techniques biologiques utilisées dans le diagnostic de la MP [4].

Prélèvement	Biomarqueurs	Évaluation
LCR	- synucléine - LRRK2 - NURR1	- Utile dans le diagnostic de la MP préclinique - Ne permet pas d'apprécier la progression de la maladie
Sang	- synucléine - ST13 - urate	- Utile dans le diagnostic de la MP préclinique

Quelques spécifications Médicales sont données comme suit:

- Liquide céphalo rachidien (LCR).
- Leucine Rich Repeat Kinase 2 (LRRK2).
- Nucléaire récepteur lié une protéine(NURR1).
- Suppression des Tumorigénicité (ST13).

1.3 Modalités de diagnostic de la maladie Parkinson

Il n'existe pas des tests médicaux définitifs pour détecter cette maladie, ce qui rend son diagnostic précis. Avec l'évaluation des technologies et des outils de calcul de plus en plus performants, plusieurs techniques ont été développées pour améliorer la précision et la fiabilité du diagnostic et le suivi de la maladie de Parkinson. Ces techniques permettent de détecter la maladie dès ces premiers stades, ainsi d'éviter les visites physiques fréquentes pour l'examen cliniques et réduire les charges financières.

De nouveaux moyens de diagnostics basés sur le traitement du signal sont apparus ces dernières années, En effet, dans la littérature, diverses méthodes développées pour le diagnostic de la maladie de la Parkinson reposent sur différentes modalités physiologiques [1].

1.3.1 Ecriture manuscrite

L'écriture manuscrite est un indicateur important dans le diagnostic de certaines maladies neurologiques telles que la maladie d'Alzheimer et celle de Parkinson. Ces maladies affectent la coordination des mouvements et la précision de l'écriture. Les patients atteints d'Alzheimer présentent une faiblesse dans le contrôle moteur, tandis que ceux atteints de Parkinson montrent une micrographie, une lenteur dans les mouvements et des tremblements. Des études ont démontré que l'analyse de l'écriture manuscrite peut contribuer au diagnostic et au suivi précoce de ces maladies [7]

1.3.2 L'électroencéphalogramme (EEG)

L'électroencéphalogramme (EEG) est considéré comme un outil efficace et largement utilisé dans le diagnostic de la maladie de Parkinson, en raison de sa capacité à enregistrer l'activité cérébrale de manière instantanée et sur de longues périodes. Cette caractéristique en fait un moyen approprié pour l'analyse des schémas neuronaux associés à divers troubles neurologiques. Grâce à ces avantages, l'EEG est devenu un instrument essentiel dans la détection et le diagnostic de nombreuses maladies neurologiques. Ces dernières années, de nombreuses recherches se sont orientées vers l'intégration des signaux EEG avec des techniques d'apprentissage automatique afin de développer des systèmes de diagnostic intelligents et plus précis pour la détection précoce de la maladie de Parkinson [\[8\]](#)

1.3.3 L'accélérométrie

L'accélérométrie est une technique non invasive reposant sur des capteurs généralement intégrés dans des montres intelligentes ou des dispositifs portables. Elle est utilisée pour surveiller les symptômes moteurs de la maladie de Parkinson, tels que les tremblements et la bradykinésie. Cette technologie a démontré son efficacité à travers plusieurs études ayant permis de collecter et d'analyser des données provenant d'un grand nombre de patients sur de longues périodes. Ces résultats confirment que l'accélérométrie constitue un outil prometteur, fiable et précis pour la détection précoce et continue de la maladie de Parkinson [\[9\]](#)

1.3.4 Electromyographiques (EMG)

Les signaux électromyographiques (EMG) constituent un outil efficace pour détecter les maladies, en localiser la source et en comprendre l'étiologie, grâce à l'analyse des caractéristiques des ondes électriques enregistrées à partir des muscles. Ces techniques aident les médecins à établir un diagnostic précis. [\[10\]](#)

1.3.5 Voix

Avec l'augmentation de la prévalence de la maladie de Parkinson après 60 ans et l'allongement de l'espérance de vie grâce aux avancées médicales, le besoin de développer des systèmes de diagnostic précis et fiables devient une nécessité. Une solution prometteuse permettant le dépistage précoce et le suivi à distance des patients atteints de la maladie de Parkinson consiste à utiliser les technologies avancées du télédiagnostic. Actuellement, les technologies de télédiagnostic s'appuient sur l'analyse de la gravité des symptômes à l'aide d'outils non invasifs.

Parmi eux, les troubles vocaux, qui touchent environ 90 % des patients aux premiers stades de la maladie. C'est pourquoi les approches basées sur l'analyse de la voix sont devenues un enjeu majeur dans la détection précoce de la maladie de Parkinson.

L'analyse vocale repose sur plusieurs paramètres acoustiques permettant de différencier les personnes saines des patients atteints de Parkinson. L'extraction et l'analyse de ces paramètres permettent de mettre en évidence les altérations vocales caractéristiques de la maladie de Parkinson, ouvrant ainsi la voie à des outils de diagnostic plus accessibles et efficaces. Les troubles vocaux tels que la dysphonie, apparaissent à un stade avancé de la maladie de Parkinson et affectent la clarté de la parole. Ils résultent de l'atteinte des organes et structures cérébrales impliqués dans la production vocale. Une compréhension du mécanisme de production vocale permet d'analyser ces altérations [\[4\]](#)

1.4 Fonctionnement d'un système de diagnostic de la maladie de Parkinson

Les systèmes de diagnostic de la MP basé sur les modalités précédemment présentées peuvent être considérés comme des systèmes de reconnaissance de formes qui reposent sur une phase d'apprentissage et une phase de test. Le fonctionnement d'un système de diagnostic automatique de la MP est illustré sur la figure (1.1).

La phase d'apprentissage a pour objectif de modéliser la classe des signaux vocaux de personnes atteintes de la MP (classe P: Parkinson) et la classe des signaux de personnes saines (classe NP: Non Parkinson) en utilisant une base de données constituée des signaux vocaux étiquetés en classes P et NP. Alors que, la phase de test consiste à identifier la classe du signal vocal d'entrée en utilisant des classificateurs tels que KNN, GMM, HMM et SVM ainsi que des modèles des classes appris durant la phase d'apprentissage. Cette dernière phase permet également d'évaluer les performances du système en utilisant le taux de reconnaissance comme mesure de performances. Chacune de ces phases se base sur une étape d'extraction de paramètres (caractéristiques) discriminants des différentes classes.

L'étape d'extraction consiste à découper le signal en fenêtres d'analyse chevauchées, puis à convertir chaque fenêtre en un vecteur de paramètres discriminants en utilisant des techniques d'analyse des signaux. Ainsi, chaque signal est converti en une séquence de vecteurs de paramètres.




Figure 1.1 : Architecture d'un système de diagnostic de la maladie de Parkinson

1.5 Méthodes de classification

De nombreuses approches de classification telles que KNN, ANN, SVM, GMM et HMM peuvent être appliquées aux systèmes de diagnostic. Chaque méthode présente ses propres avantages et limites. Notre étude se concentre sur les classificateurs HMM et GMM qui seront utilisés pour le diagnostic de la MP basé sur l'analyse de la voix.

1.5.1 Classificateur GMM

Le classificateur GMM fonctionne en deux étapes : une phase d'apprentissage, où les paramètres des modèles sont entraînés à partir d'échantillons d'entraînement représentant chaque classe, puis une phase de classification, où les observations de test sont attribuées à la classe la plus probable [11].

Le modèle de mélange gaussien (GMM) est un modèle probabiliste constitué d'une fonction de densité de probabilité paramétrique, exprimée comme une somme pondérée de plusieurs composantes gaussiennes. L'estimation de ses paramètres repose sur l'algorithme EM (Expectation-Maximization) qui permet de segmenter les données d'une classe en sous-groupes homogènes, chacun étant modélisé par une distribution de probabilité gaussienne [11].

En général, les données sont représentées sous forme de vecteurs à d dimensions. Elles peuvent être interprétées comme des variables aléatoires multidimensionnelles x de dimension d , modélisées à l'aide de fonctions de densité de probabilité (pdf) issues d'un mélange gaussien, défini comme suit :

$$f(x) = \sum_{i=1}^k \frac{\alpha_i}{\sqrt{(2\pi)^d |\Sigma_i|}} \exp\left(-\frac{1}{2}(x - \mu_i)' \cdot \Sigma_i^{-1} \cdot (x - \mu_i)\right) \quad 1.1$$

K : est le nombre de composantes gaussiennes.

μ_i et Σ_i sont respectivement le vecteur de moyennes et la matrice de covariance de la $i^{\text{ème}}$ gaussienne, α_i est le poids de la $i^{\text{ème}}$ gaussienne vérifiant la condition : $\sum_{i=1}^K \alpha_i = 1$. $|\Sigma_i|$ est le déterminant de la matrice Σ_i

Dans notre travail, cette modélisation est réalisée en langage Matlab à l'aide de la fonction `gmdistribution.fit` pour l'estimation des paramètres du modèle, et de la fonction `pdf` pour l'étape de classification.

1.5.2 Classificateur HMM

Le classificateur HMM est très utilisé dans le domaine de reconnaissance de formes pour entraîner des modèles dynamiques à partir de chaînes d'observations durant la phase d'apprentissage et d'identifier la classe de la chaîne d'observations durant la phase de test.

1.5.2.1 Modèles de Markov cachés

Les modèles de Markov sont des modèles probabilistes importants, introduits pour la première fois au début du XX^e siècle par le mathématicien russe Andreï Markov. Ces modèles sont principalement utilisés pour prédire l'état futur d'un système, en se basant uniquement sur son état actuel, sans tenir compte des états précédents. Un modèle de Markov décrit un système avec un nombre fini d'états, où chaque état a une certaine probabilité de transition vers d'autres états. Les modèles de Markov sont classés en deux types principaux selon la nature des informations disponibles [6]:

- Les modèles observables, appelés chaînes de Markov classiques, où tous les états sont visibles et directement observables.
- Les modèles de Markov cachés (HMM), qui reposent sur l'existence d'états non observables directement, mais déduits à partir d'observations séquentielles. Ces modèles sont largement utilisés dans de nombreuses applications. [6].

Les modèles de Markov cachés (HMM) sont des modèles statistiques qui supposent que le système à modéliser suit un processus de Markov comportant des états cachés, lesquels ne peuvent pas être observés directement. Dans le cadre de notre travail, les états cachés peuvent représenter des caractéristiques liées à l'état de santé d'un individu (en bonne santé ou atteint de la maladie de Parkinson), tandis que les observations correspondent à des vecteurs de paramètres acoustiques tels que les coefficients MFCC et PLP.

Le HMM est utilisé ici pour estimer la séquence la plus probable des états de santé correspondant à la séquence de vecteurs de paramètres (Observations), ce qui permet de classer avec précision les individus selon leur état de santé [6].

1.5.2.2 Définition chaîne de Markov

Un modèle de Markov caché (HMM) est un automate probabiliste qui, une fois entraîné, permet d'estimer la probabilité qu'une séquence d'observations ait été produite par ce modèle. À chaque classe de séquence d'observations est associé un modèle de Markov caché, composé d'un nombre fini d'états défini à l'avance. D'un point de vue formel, un HMM est caractérisé par un ensemble de paramètres noté $\lambda : \lambda = (L, A, B, \pi)$.

- a) L : est le nombre d'états du modèle, Un ou plusieurs états cachés.
- b) $A = a_{ij} = p(q_i / q_j)$: La matrice de probabilité de transition. La distribution de probabilité de transition est représentée par une matrice contenant des valeurs a_{ij} , où chaque valeur représente la probabilité de transition de l'état j vers l'état i . Cette matrice est utilisée pour illustrer comment le système passe d'un état caché à un autre au fil du temps.
- c) $B = b_j(X_n) = p(X_n / q_i)$: La matrice de probabilités d'émission de l'observation x_n dans l'état q_j . Les probabilités d'émission indiquent la probabilité qu'une observation (ou donnée) soit générée par un état caché particulier. Elles sont utilisées pour relier chaque état caché à l'observation qui en résulte. Ces probabilités montrent comment les sorties observables dépendent des états cachés à un moment donné t . Dans le cas des variables aléatoires continues représentant des paramètres acoustiques, chaque modèle probabiliste de b_j peut être représenté par un modèle GMM. Dans ce cas, chaque classe peut être représentée par un modèle HMM dont chaque état q_i est associé à un modèle GMM.
- d) Π : la distribution initiale des états, $\forall j \in [1, L]$, $p(q_j / q_i)$, La distribution de probabilité initiale est une distribution qui indique la probabilité qu'une chaîne de Markov commence dans chacun des états possibles. Elle est représentée par π_i , la probabilité que la chaîne commence dans l'état i . Certains états peuvent avoir une probabilité initiale $\pi_j = 0$, c'est-à-dire qu'ils ne peuvent pas être un point de départ pour la chaîne. Cette distribution est utilisée pour définir l'état initial des variables cachées au moment $t = 0$.

1.5.2.3 Fonctionnalités d'un HMM

Les modèles de Markov cachés (HMM) sont liés à trois problèmes essentiels, chacun nécessitant un algorithme spécifique pour être résolu [\[12\]](#) [\[13\]](#) :

- Problème d'évaluation de la vraisemblance : En connaissant les paramètres du modèle ainsi que les données observées, on peut calculer la probabilité d'observer ces données. Ce calcul peut être réalisé de manière efficace en utilisant l'algorithme Forward-Backward.
- Problème du décodage : À partir des paramètres du modèle et des données observées, il s'agit de déterminer la séquence d'états cachés la plus probable. Ce problème est résolu à l'aide de l'algorithme de Viterbi, qui repose sur la programmation dynamique pour identifier le chemin le plus probable d'états cachés ayant conduit à la séquence d'observations, également appelé chemin de Viterbi
- Problème d'apprentissage : À partir des données observées, l'objectif est d'estimer les paramètres du modèle. Ce problème est généralement résolu à l'aide de l'algorithme de Baum-Welch, une forme particulière de l'algorithme de maximisation des attentes (EM). Cet algorithme permet d'entraîner un modèle de Markov caché (HMM) en estimant, selon le principe du maximum de vraisemblance, les probabilités de transition entre états et les probabilités d'émission.

Ces trois algorithmes constituent les fondements des modèles de Markov cachés (HMM). Ils permettent respectivement de calculer la probabilité d'une séquence observée, de déterminer la séquence la plus probable d'états cachés, et d'estimer les paramètres du modèle à partir des données.

Dans le cadre de notre travail, nous avons utilisé la boîte à outils HTK, qui intègre l'algorithme de Baum-Welch pour l'estimation des modèles HMM à partir de la base de données d'apprentissage, ainsi que l'algorithme de Viterbi pour l'étape de décodage et l'identification des classes à partir des signaux de test.

1.6 État de l'art sur les systèmes de diagnostic de la maladie de Parkinson

Le tableau 1.3 illustre quelques travaux de recherches sur le diagnostic de la maladie de Parkinson basé sur l'analyse de la voix, en détaillant brièvement le classificateur utilisé, la méthode d'extraction, la base de données, l'année de publication ainsi que le résultat obtenu.

Tableau 1.3 : Les recherches sur le diagnostic de la maladie de Parkinson basé sur l'analyse de la voix

Reference	Année	Base de Données	Méthode d'Extraction	classificateursr	Résultats
[14]	2024	MDVR-KCL (enregistrements téléphoniques)	MFCC , GTCC, filtrage des données	SVM	Précision de 90 %
[15]	2024	Enregistrements vocaux du CHU de Varsovie	Caractéristiques de phonation, articulation, prosodie , sélection SFFS, Relief, Fisher Score	k-NN (1-nn), SVM	k-NN : 92.2 % précision, 91.1 % sensibilité, 93.3 % spécificité
[16]	2021	MDVR-KCL et Italian Parkinson's Voice and Speech Database	Jitter, Shimmer, MFCC	SVM + 6 autres classifieurs	SVM : précision 98 %, F1-score 99 %
[17]	2019	38 enregistrements vocaux — 18 sujets sains et 20 patients atteints de la maladie de Parkinson	Transformée en ondelettes, coefficients (MFCC)	SVM	Meilleur taux de reconnaissance : 86,84 %,
[18]	2023	Dataset « z » (Caractéristiques vocales)	MFCC, Jitter, Shimmer, NHR, HNR, RPDE, DFA, PPE, etc.	LightGBM, XGBoost, AdaBoost, Bagging, SVM	LightGBM : précision 96 %, F1-score 90.2 %
[19]	2024	81 enregistrements vocaux	Transformée en ondelettes, Coefficients (MFCC)	CNN , RNN, MKL, MLP	Exactitude (accuracy) : 91.11 %, Précision : 89.84 %

1.7 Exemple d'un système de diagnostic de la MP utilisant la modalité EMG

Le système consiste à classer les signaux EMG, en utilisant l'extraction de paramètres basée sur la transformée en ondelettes, et le classificateur ANN combiné avec la stratégie de la règle de vote.




Figure 1.2 : Schéma fonctionnel du système de classification [20]

L'étape d'extraction consiste à extraire des paramètres de différents descripteurs tels que DWE, LWE et WCC, calculés à partir des coefficients de détails et d'approximation de chaque niveau de décomposition dyadique de la DWT. Ainsi, chaque signal EMG est converti en une séquence de vecteurs de paramètres DWE, LWE ou WCC. Dans l'étape de classification, les auteurs ont proposé de classer chaque vecteur de paramètres en classe P ou NP en utilisant le classificateur ANN, puis appliquer la stratégie de la règle de vote sur la séquence d'indices de classes obtenues pour chercher la classe la plus votée représentant la classe du signal d'entrée. Les performances du système sont évaluées en utilisant la base de données ECOTECH. Dans ce travail, le taux de reconnaissance TR est utilisé comme une mesure de performances:

$$TR = \frac{\text{nombre de signaux correctement reconnus}}{\text{nombre total des signaux de test}} \quad 1.2$$

1.8 Conclusion

Dans ce chapitre, nous avons exploré les principaux aspects de la maladie de Parkinson ainsi que les différentes modalités de son diagnostic, avec un intérêt particulier pour l'analyse des signaux vocaux. Étant donné que les troubles vocaux figurent parmi les premiers symptômes observés chez les patients atteints de cette maladie, l'analyse de la voix pourrait constituer un outil pertinent pour un diagnostic précoce. Dans le chapitre suivant, nous nous intéresserons à l'extraction des paramètres acoustiques et à leur exploitation dans la conception d'un système de diagnostic de la MP basé sur le classificateur GMM combiné avec la stratégie de la règle de vote

.

Chapitre 2

Système de Diagnostic de la Maladie de Parkinson basé sur l'analyse de la Voix

2.1 Introduction

Le signal acoustique reflète une série d'informations biologiques importantes telles que l'identité du locuteur, son état émotionnel, son sexe, son âge et l'état pathologique de sa voix, ce qui met en évidence les changements dynamiques de l'appareil vocal. La maladie de Parkinson affecte la voix, et environ 90 % des patients présentent des troubles vocaux [21].

Étant un biomarqueur précoce, la voix permet un diagnostic anticipé. Contrairement aux méthodes traditionnelles basées sur l'imagerie, l'analyse vocale avec des algorithmes avancés offre un suivi efficace de la maladie. [21]. L'extraction des caractéristiques acoustiques permet de transformer les signaux vocaux en données numériques, une étape essentielle pour diagnostiquer des maladies à partir de la voix.

Les caractéristiques acoustiques extraites du signal vocal, comme LPC, LPCC, MFCC et PLP, permettent d'analyser et de représenter la distribution de l'énergie spectrale sur de courtes périodes. Ces paramètres sont extraits à intervalles réguliers, et des dérivées temporelles (première Δ et deuxième $\Delta\Delta$) sont souvent ajoutées pour compléter la représentation et améliorer la précision de l'analyse vocale.

Dans ce chapitre, nous aborderons les différentes étapes d'extraction des coefficients MFCC et PLP, qui reposent sur la conversion du signal vocal en une forme numérique. De plus, nous aborderons l'utilisation des Modèles de Markov Cachés (HMM) dans la classification des signaux vocaux, ce qui renforce l'efficacité du système dans le diagnostic de la maladie de Parkinson.

2.2 Définition du signal parole

Le signal parole est un signal complexe, non stationnaire et redondant, dont la structure varie au cours du temps. Il peut présenter un caractère semi-périodique, comme dans le cas des sons voisés, ou être plus aléatoire, notamment pour les sons fricatifs. La parole est constituée d'une alternance de sons et de silences, servant de principal vecteur à la transmission de la pensée à travers un système de sons articulés [22].

2.3 Caractéristiques du signal de parole

Le signal vocal se distingue généralement par des paramètres prosodiques largement exploités dans divers domaines du traitement du signal, notamment l'identification du locuteur, la reconnaissance de la parole et l'analyse des émotions. Ces paramètres prosodiques incluent:

- La fréquence fondamentale (vibration des cordes vocales).
- L'intensité de la voix (ou énergie).
- La durée successive des segments syllabiques.

2.4 2.4 Traitement de la parole

Le traitement de la parole est une discipline scientifique située à l'intersection du traitement numérique du signal et de la linguistique. Il connaît depuis longtemps une expansion significative, étroitement liée aux avancées dans le domaine des communications et des technologies. Les différentes fonctions du traitement du signal vocal sont représentées dans la figure (2-1). Parmi ces fonctions, on retrouve l'analyse, le codage, la synthèse, la reconnaissance de la parole, l'identification du locuteur, la détection des émotions et la reconnaissance de la langue. [23]




Figure 2.1 : Fonctions du traitement de la parole [24]

2.5 Systèmes de diagnostic de la MP proposés

Nous proposons deux systèmes de diagnostic de la maladie de Parkinson, le premier se base sur le classificateur HMM, tandis que la deuxième repose sur le classificateur GMM, inspiré de [20]. Une étude comparative entre les performances de ces systèmes sera menée et détaillée dans le chapitre 3.

Le premier système considère chaque signal comme une séquence d'observations à classer entièrement en utilisant le classificateur HMM. Plus particulièrement, chaque signal est converti en une séquence de vecteurs acoustiques, ensuite le classificateur est appliqué sur cette séquence pour identifier sa classe en utilisant les modèles HMM des classes appris durant la phase d'apprentissage. Alors que le deuxième système classe chaque vecteur acoustique appartenant à la séquence de vecteurs correspondant au signal en classe P ou NP en utilisant les modèles GMM de ces classes. Ensuite; la stratégie de la règle de vote est appliquée sur la séquence d'indices de classes pour trouver la classe la plus votée correspondant à la classe du signal.

2.5.1 Système de diagnostic de la MP basé sur le classificateur HMM

Le schéma de fonctionnement de notre système de diagnostic basé sur le classificateur HMM combiné avec l'extraction des paramètres MFCC ou PLP, est illustré à la figure 2.2. Le fonctionnement du système se déroule en deux phases principales : une phase d'apprentissage et une phase de test.




Figure 2.2 : Schéma du système diagnostique de la MP basé sur le classificateur HMM

2.5.2 Système de diagnostic de la MP basé sur le classificateur GMM combiné avec la stratégie de la règle de vote

Dans ce système, nous proposons d'utiliser le classificateur GMM combiné avec la stratégie de la règle de vote pour la tâche de diagnostic de la MP. Durant la phase d'apprentissage; chaque classe des signaux parole P ou NP est modélisée par un modèle GMM en utilisant l'algorithme EM.

Durant la phase de test, chaque vecteur de paramètres MFCC ou PLP appartenant à la séquence de vecteurs correspondant au signal de test est classifié par le classificateur GMM, ensuite la stratégie de la règle de vote est appliquée sur la séquence d'indices de classes obtenue pour trouver la classe la plus votée qui correspond à la classe du signal. Le schéma de fonctionnement d'un système de diagnostic basé sur le classificateur GMM est illustré à la figure 2.3.




Figure 2.3 : Schéma du système diagnostic basé sur le classificateur GMM

Les performances peuvent être évaluées en considérant le taux de classification des signaux TCS et le taux de classification des vecteurs TCV.

$$TCV = \frac{\text{nombre des vecteurs de la base de test correctement reconnus}}{\text{nombre total des vecteurs de la base de test}} \quad 2.1$$

$$TCS = \frac{\text{nombre des signaux de la base de test correctement reconnus}}{\text{nombre total des signaux de la base de test}} \quad 2.2$$

Le TCV donne une évaluation globale du système en tenant compte l'ensemble entière des vecteurs de la base de test sans considérer l'appartenance aux signaux, alors que le TCS donne une évaluation sur l'ensemble des signaux. Ce dernier est la mesure réelle prise en compte en pratique.

2.6 Extraction de paramètres

L'analyse de la parole consiste à convertir le signal vocal en vecteurs de paramètres (caractéristiques) discriminants des différentes classes pour faciliter sa classification. La parole étant un signal non stationnaire mais localement stationnaire, elle est analysée sur de courtes fenêtres de 10 à 30 ms avec chevauchement, afin d'en extraire des caractéristiques à chaque intervalle [25].

2.6.1 Coefficients cepstraux sur l'échelle Mel (MFCC)

MFCC est l'abréviation de Mel- frequency Cepstral Coefficients. Les coefficients MFCC, représentent des caractéristiques spectrales du son. Les coefficients MFCC sont extraits en appliquant la transformée cosinus inverse du logarithme du spectre de l'énergie d'un segment de parole. L'énergie spectrale est calculée à l'aide d'un ensemble de filtres répartis selon l'échelle Mel, une échelle qui repose sur une distribution non linéaire des fréquences afin de simuler la perception humaine des sons. Puis en appliquant une transformée appelée cosinus inverse permettant d'obtenir des coefficients décorrélés [26].

2.6.2 Étapes de calcul du vecteur de paramètres MFCC

L'extraction des paramètres acoustiques MFCC se déroule généralement en plusieurs étapes, telles qu'illustrées sur la Figure 2.4.




Figure 2.4 : Schéma fonctionnel des étapes de calcul des coefficients MFCC

2.6.2.1 Prétraitement du signal (La préaccentuation)

La préaccentuation est considérée comme la première étape de MFCC, l'objectif du prétraitement est de nettoyer le signal vocal des bruits et des déformations afin de faciliter l'extraction d'informations importantes et utiles. Après échantillonnage, le signal $x[n]$ subit une préaccentuation afin de compenser la faible énergie des hautes fréquences par rapport aux basses fréquences. Cette étape consiste à faire passer le signal échantillonné dans un filtre numérique à réponse impulsionnelle finie de première ordre donné comme suite : [\[27\]](#)

$$H(z) = 1 - \alpha Z^{-1} \text{ avec } 0.9 \leq \alpha \leq 1 \quad 2.3$$

Ainsi le signal pré-accentué est lié au signal échantillonné par la formule suivante :

$$Y[n] = x[n] - \alpha x[n-1] \quad 2.4$$

2.6.2.2 Fenêtrage

Le signal audio est découpé en petits morceaux de durée fixe, appelés fenêtres ou trames, qui durent en général entre 20 et 40 millisecondes. Ce découpage permet de mieux analyser le signal. Pour éviter les coupures brusques au début et à la fin de chaque morceau, on utilise une forme spéciale de fenêtre appelée fenêtre de Hamming [\[28\]](#).

2.6.2.3 La transformée de Fourier discrète

La Transformée de Fourier Discrète (TFD) est calculée à l'aide de l'algorithme FFT (Fast Fourier Transform). Cette transformation permet de convertir chaque trame fenêtrée de N échantillons du domaine temporels en domaine fréquentiel. Les valeurs obtenues sont appelées le spectre [\[28\]](#).

$$X_K = \sum_{n=0}^{N-1} x_n e^{-\frac{2\pi i k n}{N}} \quad k = 0, \dots, N-1 \quad 2.5$$

Où :

$X(k)$ est la sortie DFT.

N est le nombre d'échantillons dans la trame.

2.6.2.4 Banc de filtres à l'échelle Mel et Log

L'échelle de Mel, proposée en 1937 par Stevens et Volkman [29], ressemble à la manière dont l'être humain perçoit les sons. Elle repose sur un ensemble de filtres qui analysent les fréquences comme le fait l'oreille humaine, avec une plus grande sensibilité aux basses fréquences, ce qui permet d'extraire des coefficients reflétant la perception auditive réelle. la formule de conversion des fréquences en échelles Mel est [28]:

$$M(f) = 2595 \log \left(1 + \frac{f}{700} \right) \quad 2.6$$

Le banc de filtres Mel comprend entre 20 et 40 filtres triangulaires de surface unitaire appliquée à l'ensemble des trames du signal pour extraire les caractéristiques spectrales. Il est réparti sur les basses et les hautes fréquences, ces dernières sont espacées linéairement jusqu'à 1 KHz; puis logarithmiquement jusqu' aux fréquences maximales, chaque filtre (triangle) possède une fréquence minimale et maximale propre [28].

La relation entre la fréquence en Hertz et celle de l'échelle Mel est linéaire en dessous de 1000 Hz et logarithmique au-dessus de 1000 Hz comme illustré dans la Figure 2.5




Figure 2.5 : Relation entre la fréquence en Hertz et en échelle Mel. [28]

L'application de logarithme après le passage par les filtres Mel (Mel Filter Bank) permet de réduire l'échelle dynamique des énergies spectrale extraites.

Offrant ainsi une représentation plus cohérente, des composants spectraux essentiels à la reconnaissance vocale. Les coefficients logarithmiques sont obtenus en appliquant, l'équation suivante :

$$S(m) = 20 \log_{10} \left(\sum_{k=0}^{N-1} |X(k)H(k)| \right), \quad 0 < m < M \quad 2.7$$

Grâce à cette transformation les coefficients MFCC deviennent plus résistants aux variations des conditions d'enregistrement.

Où :

- M est le nombre de filtres à l'échelle Mel de 20 à 40.
- X(k) est la FFT de la trame.
- H(k) est la fonction de transfert du filtre Mel.

2.6.2.5 Transformée en cosinus discrète

La transformée en cosinus discrète DCT, est une transformation mathématique linéaire, qui permet de décorrélérer les coefficients extraits, et de concentrer l'essentiel, de l'énergie du signal dans un nombre limité de composants. Les coefficients C(n) sont calculés par l'équation.

$$C(n) = \sum_{m=0}^{N-1} s(m) \cos \left(\frac{\pi n \left(m - \frac{1}{2} \right)}{M} \right), \quad 0 \leq n \leq M \quad 2.8$$

Où :

- C(n) : les coefficients MFCC.
- S(m) : spectre logarithmique.
- N : le nombre d'échantillons dans chaque trame.
- M : le nombre des bancs de filtres.

Les premiers coefficients obtenus ensuite assemblés pour constituer le vecteur de caractéristique MFCC, comme présenté dans la figure (2.6)




Figure 2.6 : Les caractéristiques statiques MFCC [28]

2.6.2.6 Calcul des paramètres dynamiques des MFCC

Les coefficients dynamiques des MFCC complètent les informations fournies par les coefficients MFCC statiques, qui permettent de représenter la dynamique des propriétés acoustiques d'un signal vocal [30].

Le calcul des paramètres dynamique des MFCC se fait généralement en utilisant les premières et deuxièmes dérivées des coefficients MFCC statiques. Les premiers dérivés notés (Δ) indiquant la vitesse de variation des MFCC, tandis que les deuxièmes dérivées notées ($\Delta\Delta$) représentent l'accélération de ces variations. L'intégration de ces paramètres dynamiques dans les systèmes de diagnostic vocal renforce leur précision, leur capacité et leur robustesse au bruit. Les paramètres dynamiques capturent des données temporelles complémentaires qui permettent mieux représenter les aspects temporels de la parole [30].

Couramment, 39 coefficients MFCC sont extraits et utilisés dans plusieurs domaines tels que la reconnaissance de la parole, la reconnaissance d'émotions; etc. Ces coefficients sont répartis en 12 coefficients MFCC statiques, le logarithme d'énergie E ainsi que leurs paramètres dynamiques delta et delta delta. Cette répartition est illustrée sur la figure (2.7).




Figure 2.7 : Les caractéristiques statiques et dynamiques. [28]

2.6.3 Coefficients PLP (Perceptual Linear prediction PLP)

La version de la prédiction linéaire perceptive (PLP), développée par Hermansky, se base sur les principes de la psychophysique de l'audition humaine. Cette approche permet de filtrer et d'éliminer les informations inutiles contenues dans le signal vocal, ce qui améliore les performances des systèmes de reconnaissance vocale. Le descripteur PLP repose sur le même principe que la LPC, mais s'en distingue par la transformation des caractéristiques du son afin de les rendre plus proches de ce que perçoit réellement l'oreille humaine [5].




Figure 2.8 : Schéma fonctionnel du traitement PLP

Les étapes d'extraction du PLP sont illustrées sur la figure (2.9). Le descripteur PLP prend en compte trois aspects importants de la perception auditive : la résolution en bandes critiques, la courbe d'égal-loudness (égal niveau sonore perçu), et la relation entre l'intensité et la perception du son appelée loi de puissance ou racine cubique.




Figure 2.9 : Calcul des paramètres PLP

2.7 Conclusion

Dans ce chapitre, nous avons présenté l'analyse de signal vocal dans le cadre du diagnostic. Nous avons détaillé, les différentes étapes du calcul des MFCC et PLP, qui constituent l'une des techniques les plus utilisés pour extraire les caractéristiques acoustiques pertinentes. Cette approche permet de convertir le signal vocal en une représentation plus adaptée aux algorithmes de classification, facilitant ainsi l'identification des variations vocales associées à la maladie.

Chapitre 3

**Implémentation du système de diagnostic de
la maladie de Parkinson basé sur l'analyse de
la voix et les modèles HMM**

3.1 Introduction

L'objectif de notre projet est de développer et mettre en place un système de diagnostic acoustique fiable de la maladie de Parkinson en utilisant les modèles de Markov cachés (HMM). Ce système doit être à la fois précis, rapide et ne pas nécessiter beaucoup de mémoire ou de puissance de calcul. Il comprend deux étapes principales : une phase d'apprentissage, où le modèle est entraîné à partir d'enregistrements vocaux de patients malades et de personnes saines, et une phase de test, au cours de laquelle de nouveaux enregistrements vocaux sont classifiés afin de déterminer l'état de santé du patient et d'évaluer également les performances du système. Les deux phases reposent sur l'extraction de paramètres acoustiques discriminants, tels que les coefficients MFCC et les coefficients PLP, à partir des signaux vocaux, puis le classificateur utilise les modèles entraînés HMM pour assigner chaque enregistrement à la catégorie « malade » ou « normal ».

Dans ce travail, nous proposons l'implémentation et la mise en œuvre d'un système de diagnostic de la maladie de Parkinson basé sur l'analyse de la voix et le classificateur HMM, en utilisant la boîte d'outils HTK [\[31\]](#) sous l'environnement Matlab. En complément, nous proposons une comparaison des performances avec un autre système basé sur l'algorithme de classification GMM (modèles de mélange gaussien) combiné avec la stratégie de la règle de vote. Cet algorithme est appliqué aux vecteurs de paramètres MFCC ou PLP, et combiné la stratégie de la règle de vote pour prendre la décision concernant la classe du signal de test.

Plusieurs questions peuvent être posées afin de déterminer et de choisir les paramètres optimaux pour les deux systèmes basés respectivement sur les algorithmes GMM et HMM :

- Quel est le meilleur descripteur de paramètres ?
- Est-ce que les paramètres dynamiques améliorent les performances de ces systèmes ?
- Quel est le meilleur nombre de gaussiennes des modèles GMM des classes P et NP ?
- Quel est le meilleur nombre d'états et le meilleur nombre de gaussiennes des modèles HMM ?
- Quel est le meilleur classificateur permettant d'obtenir la meilleure précision ?

Pour répondre à ces questions, nous allons effectuer une série d'expériences portant sur chacun de ces aspects spécifiques.

3.2 Description de la base de données Italian-Parkinson's Voice And Speech

La base de données **ITALIAN-PARKINSON'S VOICE AND SPEECH** est fréquemment utilisée comme référence dans de nombreuses études de recherche. En particulier, cette base de données de signaux parole est utilisée pour le diagnostic de la MP à partir de la voix. Cette base de données se caractérise par la richesse de son vocabulaire, la haute qualité de ses signaux audio, la diversité des durées des lettres, ainsi que par la variété de ses locuteurs, issus de tranches d'âge et de genre différents.

Dans notre travail, nous nous intéressons à utiliser une partie de cette base, constituée de l'ensemble des signaux vocaux correspondant aux 5 voyelles A, E, U, I et O prononcées par 22 patients saines et 28 patients parkinsoniens, avec des répétitions de courtes et longues durées. Cette sous base de données constituée réellement de 495 signaux vocaux est répartie selon deux modes de fonctionnement du système, à savoir : le mode dépendant du locuteur et mode indépendant du locuteur. Dans le premier mode, chaque locuteur participe à la phase d'apprentissage et également à la phase de test. Dans le deuxième mode, les locuteurs impliqués dans la phase d'apprentissage ne participent pas à la phase de test. Notons que, les cinq lettres sont utilisées dans les deux modes de fonctionnement. Ainsi, on peut considérer que le fonctionnement du système est également en mode dépendant du texte.

Dans notre travail, nous nous intéressons également à évaluer les performances des systèmes de diagnostic proposés fonctionnant en modes dépendant et indépendant du locuteur.

Les détails sur l'ensemble des locuteurs sains (NP) et parkinsoniens (P) sont donnés respectivement dans les tableaux Tab 3.1 et Tab 3.2.

Tableau 3.1 : Groupe des personnes saines

Prénom	Nom de famille	Genre	ID	Prénom	Nom de famille	Genre	ID
AGNESE	P	F	F1	LISCO	G	M	M12
ANGELA	C	F	F2	LUIGI	P	M	M13
ANGELA	G	F	F3	MARTACRISTTA	P	F	F14
ANTONIETTA	P	F	F4	MICHELE	G	M	M15
ANTONIO	C	M	M5	NICOLA	P	M	M16
BRIGIDA	C	F	F6	PORCELLI	A	M	M17
GILDA	C	F	F7	SUMMO	L	F	F18
GIOVANNA	G	F	F8	TERESA	M	F	F19
GIOVANNI	B	M	M9	VITANTONIO	D	M	M20
GRAZIA	G	F	F10	VITO	A	M	M21
LEONARDA	F	F	F11	VITO	L	M	M22

Chapitre 3 : Implémentation d'un système de diagnostic de la maladie de Parkinson basé sur l'analyse de la voix et les modèles HMM

Tableau 3.2 : Groupe de personnes parkinsoniennes

Prénom	Nom de famille	Genre	ID	Prénom	Nom de famille	Genre	ID
Domenico	C	M	M1	Roberto	R	M	M15
Felicetta	C	F	F2	Vito	S	M	M16
Leonarda	L	F	F3	Antonia	G	F	F17
Lucia	R	F	F4	Daria	L	F	F18
Roberto	R	M	M5	Giovanni	M	M	M19
Luigi	B	M	M6	Giovanni	N	M	M20
Nicola	S	M	M7	Giulia	L	F	F21
Saverio	S	M	M8	Giulia	P	F	F22
Ugo	B	M	M9	Giustina	M	F	F23
Vito	S	M	M10	Mario	B	M	M24
Anna	B	F	F11	Nicola	M	M	M25
Michele	C	M	M12	Nicolò	C	M	M26
Nicola	S	M	M13	Vito	L	M	M27
Roberto	L	M	M14	Vito	S	M	M28

3.2.1 Répartition de la base de données en mode Indépendant

La répartition de la base de données en mode indépendant est décrite en détails dans les tableaux Tab. 3.3, Tab. 3.4, Tab. 3.5 et Tab. 3.6. Plus particulièrement, les tableaux Tab. 3.3 et Tab. 3.4 donnent des détails sur la répartition de l'ensemble des signaux des locuteurs sains (NP), respectivement en base d'apprentissage (APP) et base de test. Alors que, les tableaux Tab. 3.5 et Tab. 3.6 donnent des détails sur la répartition de l'ensemble des signaux des locuteurs Parkinsoniens (P), respectivement en base d'apprentissage et base de test. Ces détails concernent le nom du locuteur et son genre ainsi que le nombre de signaux (Nb-signaux). Chaque base est constituée des signaux des voyelles de courtes et longues durées.

Tableau 3.3 : Répartition des signaux des locuteurs NP dans la base d'apprentissage, en mode indépendant.

Chapitre 3 : Implémentation d'un système de diagnostic de la maladie de Parkinson basé sur l'analyse de la voix et les modèles HMM

Tableau 3.3 : Répartition des signaux des locuteurs NP dans la base d'apprentissage, en mode indépendant.

Nom du LOCUTEUR	F1	F2	F3	F4	M5	F6	F7	F8	M12	M13	M15	Total ----- 11
Genre	F	F	F	F	M	F	F	F	M	M	M	-
Nb-Signaux	10	10	10	10	10	10	10	10	10	10	10	110

Tableau 3.4 : Répartition des signaux des locuteurs NP dans la base de test, en mode indépendant

Nom du LOCUTEUR	F9	F10	F11	F14	M16	M17	F18	F19	M20	M21	M22	Total ----- 11
GENRE	F	F	F	F	M	M	F	F	M	M	M	-
Nb-Signaux	10	10	10	10	10	10	10	10	10	10	10	110

Tableau 3.5 : Répartition des signaux des locuteurs P dans la base d'apprentissage, en mode indépendant

Nom du LOCUTEUR	M1	F2	F3	F4	M5	M6	M7	M8	M9	M10	F11	M12	M13	M14	F17	Total ----- 15
Genre	M	F	F	F	M	M	M	M	M	M	F	M	M	M	F	-
NB-signaux	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	150

Tableau 3.6 : Répartition des signaux des locuteurs P dans la base de test, en mode indépendant

Nom du LOCUTEUR	M15	M16	F18	M19	M20	F21	F22	F23	M24	M25	M26	M27	M28	Total ----- 13
Genre	M	M	F	M	M	F	F	F	M	M	F	M	M	-
NB-signaux	10	10	10	10	10	10	10	5	10	10	10	10	10	125

Le tableau 3.7 résume la répartition en mode indépendant des signaux en base d'apprentissage et base de test.

Tableau 3.7 : Répartition au mode indépendant des signaux en base d'apprentissage et base de test

Nb-signaux	Apprentissage	Test	Total
NP	110	110	220
P	150	125	275

3.2.2 Répartition de la base de données en mode Dépendant

La répartition des signaux des locuteurs sains en base d'apprentissage et de test au mode dépendant consiste à choisir pour chaque locuteur de la base, 5 signaux pour l'apprentissage et 5 pour le test (sauf le cas du locuteur F23). Ainsi, cette répartition est résumée dans le tableau Tab. 3.8.

Tableau 3.8 : Répartition au mode dépendant des signaux en base d'apprentissage et base de test

Nb-signaux	Apprentissage	Test	Total
NP	110	110	220
P	140	135	275

3.3 Implémentation du système basé sur les modèles HMM

3.3.1 Phase d'apprentissage

L'implémentation de la phase d'apprentissage consiste premièrement à convertir chaque signal vocal en une séquence de vecteurs de paramètres acoustiques en utilisant la commande Hcopy de la boîte HTK, puis à modéliser chaque classe de signaux P ou NP par un modèle HMM dont chaque état est associé à un modèle GMM en utilisant la commande Herest. Dans notre travail, nous avons choisis les descripteurs MFCC et PLP.

3.3.1.1 Extraction des paramètres

L'extraction des paramètres transforme le signal vocal en vecteurs de 39 paramètres, extraits de trames de 30 ms avec 10 ms de recouvrement. Ces paramètres sont obtenus à l'aide de l'outil HCopy de la bibliothèque HTK [\[31\]](#), appliqué sur un fichier audio au format wav représentant le signal d'entrée. La commande suivante permet de convertir ce signal en une séquence de vecteurs (MFCC ou PLP) de 39 dimensions.

La ligne de commande pour l'exécution de HCopy s'écrit comme suit :

HCopy – C 'file.conf.' – S 'liste.wav2mfc'

Tel que :

- **File.conf.** : est un fichier texte qui regroupe les paramètres nécessaires à la configuration de l'étape d'extraction des coefficients acoustiques MFCC ou PLP .
- **liste.wav2mfc** : est un fichier texte qui définit le nom et le chemin de chaque fichier audio à traiter, ainsi que les noms et chemins des fichiers cibles contenant les coefficients associés.




Figure 3.1 : le fichier texte liste.wav2mfc




Figure 3.2 : les vecteurs MFCC résultant

3.3.1.2 Outils d'apprentissage

La construction des modèles HMM se déroule en trois étapes principales :

- L'initialisation des modèles.
- Leur réestimation.
- Et l'augmentation progressive du nombre de gaussiennes.

3.3.1.2.1 L'initialisation des modèles HMM

L'étape d'initialisation a pour but d'initialiser l'ensemble des modèles HMM à l'aide d'un modèle HMM initial. Ce dernier, nommé modèle prototype, détermine la topologie des modèles de classes. Ce modèle prototype précise la dimension des vecteurs de caractéristiques, le type des paramètres utilisés, le nombre d'états ainsi que la topologie du modèle (par exemple : gauche - droite).

Dans notre travail, nous avons utilisé une configuration composée de 5 États (trois états actifs et deux états non actifs d'entrée et de sortie), Chaque état est associé à un modèle GMM, qui est représenté par un vecteur de moyennes nul et une matrice de covariance diagonale. Cette matrice de covariance diagonale implique que les caractéristiques ou les observations sont indépendantes les unes des autres au sein de chaque état du HMM. Cette hypothèse simplificatrice facilite la modélisation et réduit la complexité des calculs.

HCompV – C conf_user – f 0.001 – m – S trainlist, M hmm0 proto

- « **-C conf_user** » : désigne le fichier de configuration config, qui contient les paramètres nécessaires à la configuration du modèle HMM.
- « **-S trainlist** » : désigne le fichier trainlist, qui contient une liste des fichiers de données d'apprentissage à utiliser pour l'estimation des paramètres.
- « **-M hmm0** » : définit le répertoire de sortie hmm0 où les modèles HMM initialisés seront enregistrés.
- « **Proto** » : indique le fichier du modèle prototype, qui définit la structure et les caractéristiques initiales des modèles HMM.

En lançant cette commande, l'outil HCompV de HTK procède à l'initialisation des modèles HMM. Il évalue les paramètres initiaux à partir du modèle prototype `proto` et des fichiers d'apprentissage listés dans `trainlist`. Les modèles HMM ainsi générés seront enregistrés dans le dossier `hmm0`.

 <code>proto</code>	File	1 KB	No	4 KB	83%	5/7/2
 <code>vFloors</code>	File	1 KB	No	1 KB	56%	5/7/2

Figure 3.6 : les fichiers résultant après l'exécution du command HcompV

3.3.1.2.2 Réestimation des modèles HMM

L'objectif de cette étape est d'effectuer une réestimation des paramètres des modèles de Markov cachée (HMM), correspondant aux différentes classes. Cette tâche est réalisée en utilisant l'outil `HERest` fourni par le HTK, L'outil `HERest` utilise l'algorithme de `Baum_welch`, une méthode bien connue pour la réestimation des paramètres des modèles HMM.

**`HERest -C',conf_user,' -I',file_trainmlf,' -L -t 250.0 150.0 1000.0 -S',trainlist,'
-H hmm0/macros -H /hmm0 /hmmdefs -M /hmm1 listmodel`**

- **`-C conf_user`** : Spécifie le fichier de configuration contenant les paramètres nécessaires pour la réestimation HMM.
- **`-I file_trainmlf`** : est un fichier qui contient les chemins d'accès à tous les fichiers de labellisation de la base de données d'apprentissage (voire la figure (3.7)).
- **`-S trainlist`** : spécifie le fichier `trainlist` qui liste les fichiers de données d'apprentissage à utiliser pour la réestimation.
- **`-M hmm1`** : spécifie le répertoire de sortie `hmm1` où les modèles HMM réestimés seront stockés.
- **`liste_modeles`** : spécifie le fichier contenant la liste des noms des modèles HMM à réestimer (voire la figure (3.8)).
- **`Hmmdef`** : le fichier `hmmdef` est une collection de modèles HMM représentant différentes classes (voire la figure (3.9)).
- **`Macros`** : (voire la figure (3.10)) Le fichier macro contient les paramètres généraux partagés par tous les modèles HMM, ce qui permet de mieux organiser les modèles et d'économiser les ressources.



```

#IMLF#
"*\\VAIABNINSAC46F248128171758.1ab"
AN
"
"*\\VAIAGNUTGOL52F188228171849.1ab"
AN
"
.....
.....

"*\\VUIVDIETAS479218328178945.1ab"
NR
"
"*\\VUIVL IATFOO55M388328171248.1ab"
NR
"

```

Figure 3.7 : illustration du fichier trainmlf



```

NR

```

Figure 3.8 : illustration du fichier "liste_models"

```

to
<STREAMINFO> 1 39
<VECSIZE> 39<NULLD><MFCC_E_D_A><DIAGC>
~h "AN"
<BeginHMM>
<NumStates> 7
<State> 2
<MEAN> 39
1.546805e+000 2.370236e+000 3.904026e+000 -2.502570e-001
2.543653e+000 -2.510776e+000 -2.076247e+000 -4.890743e+
000 -4.147163e+000 -3.608854e+000 -1.860716e+000 -2.211957e+000
7.182572e-001 1.575908e-003 5.305124e-004 -3.111858e-005
3.420851e-005 -1.227704e-005 -4.089999e-005 -2.774932e-004 -8.67
5584e-004 -4.573598e-004 -7.530656e-006
2.507592e-004 -9.257438e-006 -7.919783e-006 -2.962520e-005
2.683770e-005 -4.883476e-005
2.025995e-005 -4.189951e-005 -2.158229e-005
2.825371e-005 -3.627512e-005 8.163034e-005 8.881572e-005
1.883219e-005 -7.997767e-005 -2.114468e-006
<VARIANCE> 39
4.236854e+001 5.999162e+001 1.176359e+002 1.483934e+002
2.121768e+002 1.464637e+002 1.364691e+002 1.153037e+002
7.236624e+001 5.756838e+001 6.151517e+001 5.036292e+001
7.201292e-002 9.671889e-002 1.917824e-001 3.026486e-001
4.222227e-001 5.318211e-001 6.348159e-001 7.230563e-001
7.903948e-001 7.753063e-001 7.683236e-001 7.518759e-001
6.802859e-001 9.777638e-005 1.623599e-002 3.622892e-002
5.705501e-002 8.100370e-002 1.029513e-001 1.255568e-001
1.442054e-001 1.558745e-001 1.551746e-001 1.534878e-001
1.479108e-001 1.345471e-001 1.051468e-005

```

Figure 3.9 : illustration du fichier hmmdef

```

|>o <VecSize> 39 <MFCC_E_D_A>
~v varFloor1
<Variance> 39
 4.236854e-002 5.999162e-002 1.176359e-001 1.483935e-001
2.121768e-001 1.464638e-001 1.364691e-001 1.153037e-001
7.236625e-002 5.756839e-002 6.151517e-002 5.036292e-002
7.201292e-005 9.671890e-005 1.917824e-004 3.026486e-004
4.222227e-004 5.318212e-004 6.348160e-004 7.230563e-004
7.903949e-004 7.753064e-004 7.683237e-004 7.518760e-004
6.802859e-004 9.777638e-008 1.623599e-005 3.622892e-005
5.705501e-005 8.100370e-005 1.029513e-004 1.255568e-004
1.442054e-004 1.558745e-004 1.551746e-004 1.534878e-004
1.479108e-004 1.345471e-004 1.051468e-008

```

Figure 3.10 : illustration du fichier macro

3.3.1.2.3 L'augmentation de nombre de gaussiennes

L'outil HHed sert à apporter des modifications aux modèles HMM, selon ce qui est indiqué dans le fichier d'édition (silhed1). Cette commande permet de modifier les modèles HMM obtenus dans le fichier de macros (hmm3\macros) et le fichier de définitions des HMM (hmm3\hmmdef) en augmentant le nombre de gaussiennes des modèles GMM de chaque état. Après modification, les nouveaux modèles sont enregistrés dans le dossier de sortie (hmm4), où ils seront à nouveau réestimés trois fois avec l'outil HERest.

Ce processus est répété en augmentant respectivement le nombre de gaussiennes à 2, 4, 8, 16, 32, 64.

HHed -H hmm3/macros -H hmm3/hmmdefs -M hmm4 silhed1 listmodel

- **H hmm3\macros** : Spécifie le répertoire contenant les fichiers macros.
- **H hmm3\hmmdef** : Spécifie le répertoire contenant le fichier hmmdef
- **M hmm4** : spécifie le répertoire de sortie dans lequel les modèles HMM modifiés seront Stockés.
- **silhed1** : est un fichier qui contient les instructions de l'augmentation du nombre De Gaussiennes (voire la figure (3.11)).




Figure 3.11 : illustration du fichier silhed1

3.3.2 Définition du dictionnaire et du modèle du Langage

HParse est une commande du HTK utilisée pour transformer une grammaire en une structure de réseau.

HParse -C 'conf_user,' -A -D -T 1 'gram.txt' 'wnetf

- **gram.txt** : spécifie le fichier de configuration (gram.txt) contenant les règles de grammaire et les paramètres. (Figure 3.12 : Illustration du fichier gramme).
- **wnetf** : spécifie le nom du fichier de sortie pour la structure de réseau compilée.




Figure 3.12 : Illustration du fichier gramme

Lors de l'exécution de la commande HParse, l'outil prend en entrée les règles de grammaire ainsi que les paramètres définis dans le fichier de configuration (gram.txt). Et les transforme en une structure de réseau le fichier (wnetf) contient ensuite cette structure compilée.

3.3.3 Classification

La commande **Hvite** sert à réaliser l'étape de décodage en s'appuyant sur l'algorithme de Viterbi.

HVite -D -C 'conf_user,' -I '*,', -S 'testlist,' -H 'mac_file,' -H 'mod_file,' -i 'recmlf.mlf,' -w 'wnetf,' 'dic,' 'listmodel));

- **testlist** : spécifie le fichier (testlist) contenant la liste des fichiers de base de données de test
- **H mac_file -H mod_file** : Spécifie le fichier de macros (mac_file) et le Hmmdefs (mod_file).
- **i recmlf.mlf**: Spécifie le fichier de sortie (recmlf.mlf) dans lequel les étiquettes reconnues ou la sortie décodée seront stockées.

- **w wnetf** : Spécifie le fichier de réseau de mots (wnetf) représentant le modèle de langue.
- **dic** : Spécifie le fichier (dictionnaire) contient le dictionnaire ou le vocabulaire.
- **listmodel** : et le fichier (listmodel) contenant la liste des noms de modèles ou des classes à utiliser pour la reconnaissance.



Figure 3.13 ; Illustration du fichier dictionnaire

Lorsqu'une commande **Hvite** est exécutée, le programme effectue le processus de décodage à l'aide de l'algorithme **Viterbi**, qui est utilisé pour déterminer la séquence d'états la plus probable correspondant à la séquence d'observation, en se basant sur les paramètres de configuration fournie, les modèles entraînés, le modèle de langage, le dictionnaire et les paramètres acoustiques. Les étiquettes reconnues ou la sortie décodée, sont ensuite sauvegardées dans le fichier de sortie. **recmlf.mlf**.

3.3.4 Évaluation du système de reconnaissance

HResults -I ' , file_mlf_test,' -L ' , cheminbaselab , ' ,listmodel , 'recmlf.mlf >> ' , resultat

La commande **HResults** permet d'évaluer la performance d'un système de reconnaissance en comparant les étiquettes obtenues avec celles de référence.

- **I fichier_mlf_testr** : spécifie le fichier d'étiquettes de référence (file_mlf_testr) contenant les étiquettes correctes pour l'évaluation.
- **L cheminbaselab** : spécifie le répertoire (cheminbaselab) dans lequel se trouvent les fichiers d'étiquettes de référence.
- **list_model** : spécifie le fichier contenant la liste des noms de modèles ou de classes utilisés pour la reconnaissance.
- **recmlf.mlf**: spécifie le fichier d'étiquettes de sortie (recmlf.mlf) obtenu par le système de reconnaissance.
- **>> résultat** : redirige la sortie de l'évaluation vers le fichier nommé resulta pour stocker les métriques d'évaluation.

3.4 Critères d'évaluation

Le paramètre « correct » représente le taux de reconnaissance (TR) des signaux test correctement reconnus. Il est calculé selon la formule suivante :

$$TR = \frac{H}{N} \times 100 \% \quad 3.1$$

Où :

H : correspond au nombre de signaux de test correctement reconnus,

N : désigne le nombre total de signaux de test.

3.5 Expérience et résultats

Dans cette section, nous allons présenter les différentes expériences menées dans but de répondre aux différentes questions posées au début de ce chapitre.

3.5.1 Expérience 1: performances du système basé sur le descripteur MFCC en mode indépendant

La première expérience de notre étude vise à évaluer les performances du système de reconnaissance standard basé sur des modèles de Markov cachés (HMM), en configuration indépendante.

Le principal objectif de cette expérience est d'optimiser la topologie des modèles HMM en identifiant le nombre optimal d'états cachés, ainsi que le nombre optimal de composantes gaussiennes, dans le but d'améliorer les performances du système.

L'entraînement des modèles a été réalisé premièrement en mode indépendant à partir de séquences de vecteurs de paramètres MFCC. Les performances du système ont été évaluées à travers le taux de reconnaissance (TR), et les résultats obtenus nous indiquent une bonne précision, avec un TR de 88,94 % en choisissant un nombre d'état égal à 4 avec un nombre de gaussiennes égal à 8 .

Tableau 3.9 : Influence du nombre d'états HMM et de gaussiennes GMM sur les performances du système basé sur le descripteur MFCC en mode indépendant.

Nbr d'états	4	5	6	7	8	9	10
Nbr optimal de gaussiennes	8	8	4/8	8	4	64	64
TR (%)	88.94	88.94	77.87	81.28	74.04	84.28	85.53

```

le type de paramètres MFCC_E_D_A
===== HTK Results Analysis =====
Date: Thu May 22 15:51:53 2025
Ref : C:\hmm_dias\datamlf\testpros.mlf
Rec : C:\hmm_dias\datamlf\recmlf.mlf
----- Overall Results -----
SENT: %Correct=88.94 [H=209, S=26, N=235]
WORD: %Corr=88.94, Acc=88.94 [H=209, D=0, S=26, I=0, N=235]
=====

```

Figure 3.14 : Résultat de la deuxième expérience en choisissant un nombre d'état égal 4 et un nombre de gaussiennes égal à 8

3.5.2 Expérience 2: Performances du système basé sur le descripteur MFCC en mode dépendant

Cette expérience vise à optimiser la topologie des modèles HMM du système de diagnostic de la MP basé sur le descripteur MFCC en mode dépendant, en variant le nombre d'états (Nbr_e) et de gaussiennes (Nbr_g) par état. Les paramètres acoustiques sont extraits à l'aide des coefficients MFCC.

```

le type de paramètres MFCC_E_D_A
===== HTK Results Analysis =====
Date: Thu May 22 21:07:07 2025
Ref : C:\hmm_dias\datamlf\testpros1.mlf
Rec : C:\hmm_dias\datamlf\recmlf.mlf
----- Overall Results -----
SENT: %Correct=100.00 [H=245, S=0, N=245]
WORD: %Corr=100.00, Acc=100.00 [H=245, D=0, S=0, I=0, N=245]
=====

```

Figure 3.15 : Résultat de la deuxième expérience en choisissant un nombre d'état égal 7 et un nombre de gaussiennes égal à 32

Les résultats de la figure 3.15 montrent un taux TR de 100 %, indiquant que tous les signaux vocaux ont été reconnus correctement sans aucune erreur.

Le tableau (3.10) illustre le taux TR en fonction du nombre d'états et du nombre de gaussiennes optimales.

Tableau 3.10 : Taux TR pour différentes valeurs de Nbr d'état et de Nbr de gaussiennes optimales

Nbr d'états	4	5	6	7	8	9	10
Nbr optimal de gaussiennes	64	32 / 64	64	32	32	32	64
TR (%)	100	99,59	99,59	100	99.59	100	99 .59

Les résultats ont révélé une amélioration des performances par rapport au mode indépendant, avec un taux (TR) de 100 % en choisissant un nombre d'état égal à 4 avec un nombre de gaussiennes égal à 64 (ou 7 états avec un Nbr de gaussiennes égal à 32).

3.5.3 Expérience 3: Performances du système basé sur le descripteur PLP en mode indépendant

Dans cette expérience l'entraînement des modèles a été réalisé deuxièmement en mode indépendant à partir de séquences de vecteurs de paramètres PLP comme paramètres acoustiques en entrée du modèle HMM.

```

le type de paramètres PLP_E_D_A
===== HTK Results Analysis =====
Date: Thu May 22 16:18:48 2025
Ref : C:\hmm_dias\datamlf\testpros.mlf
Rec : C:\hmm_dias\datamlf\recmlf.mlf
----- Overall Results -----
SENT: %Correct=90.21 [H=212, S=23, N=235]
WORD: %Corr=90.21, Acc=90.21 [H=212, D=0, S=23, I=0, N=235]
=====
  
```

Figure 3.16 : La figure, affiche les détails des performances du système en choisissant un nombre d'état égal à 10 et un nombre de gaussiennes égal à 32

Les résultats montrent l'efficacité du descripteur PLP par rapport au descripteur MFCC.

Tableau 3.11 : Influence du nombre d'états HMM et du nombre de gaussiennes sur la performance du système _PLP en mode indépendante

Nbr d'états	4	5	6	7	8	9	10
Nbr optimal de gaussiennes	8	4	8	32	32	64	32
TR (%)	84.68	89.79	81.28	86.38	85.96	83.40	90.21

Les résultats montrent que les performances du système de reconnaissance dépend fortement du nombre d'états HMM et du nombre de composantes gaussiennes. La meilleure performance, avec un taux d'identification de **90.21 %**, est obtenue en utilisant **10** états et **32** gaussiennes, ce qui confirme l'importance d'un bon choix du modèle pour assurer de bonnes performances.


3.5.4 Expérience 4 : Performances du système basé sur le descripteur PLP en mode dépendant

Dans la quatrième expérience le descripteur PLP en mode dépendant comme paramètres acoustiques en entrée du modèle HMM. Le tableau (3.12) illustre le taux TR en fonction du nombre d'états et du nombre de gaussiennes optimales.

Tableau 3.12 : Influence du nombre d'états HMM et de gaussiennes sur la performance du système _PLP en mode dépendante

Nbr d'états	4	5	6	7	8	9	10
Nbr optimal de gaussiennes	32/64	64	32/64	32	32	32/64	32/64
TR (%)	99.18	100	99.59	100	100	100	99.18

Les résultats a montré une performance globale excellente, avec des taux de reconnaissance (TR) de 100 % dans plusieurs état 5, 7, 8, 9. Avec un nombre de gaussiennes égal à 32 et 64. Ce qui confirme son efficacité dans la reconnaissance précise des signaux vocaux.



```

le type de paramètres PLP_E_D_A
===== HTK Results Analysis =====
Date: Thu May 22 16:41:18 2025
Ref : C:\hmm_dias\datamlf\testpros1.mlf
Rec : C:\hmm_dias\datamlf\recmlf.mlf
----- Overall Results -----
SENT: %Correct=100.00 [H=245, S=0, N=245]
WORD: %Corr=100.00, Acc=100.00 [H=245, D=0, S=0, I=0, N=245]
=====

```

Figure 3.17 : La figure affiche les détails des performances du système en choisissant un nombre d'état égal à 7 et un nombre de gaussiennes égal à .32

3.5.5 Expérience 5: Système de diagnostic de la maladie de Parkinson basé sur le classificateur GMM en mode indépendant avec le descripteur MFCC

Les courbes TCV et TCS ci-dessous illustrent les performances du système basé sur le classificateur GMM dans un mode indépendant.




Figure 3.18 : Taux TCV pour classificateur GMM en mode indépendant




Figure 3.19 : Taux TCS pour classificateur GMM en mode indépendant

A partir des figures 3.18 et figure 3.19 nous pouvons donner les remarques suivantes :

- Le taux TCS présente de fortes fluctuations, avec des pics dépassant 90 % (atteignant 97.17 % pour $N_g = 9$), sans stabilité claire. De légers changements dans le nombre de composantes gaussiennes peuvent avoir un impact important sur les performances, ce qui souligne l'importance d'un réglage précis pour choisir la valeur optimale de N_g .
- La courbe TCV montre d'importantes fluctuations en fonction du nombre de composantes gaussiennes (N_g). Après une amélioration initiale, les performances deviennent instables, avec des pics atteignant 90 % et des baisses allant jusqu'à 68 %. Cela indique une forte sensibilité du modèle à la valeur de N_g , nécessitant un choix précis pour obtenir une performance optimale. Ceci, peut être expliqué par l'influence de la variabilité interlocuteur sur la robustesse du système de diagnostic de la MP.
- Les taux TCS sont systématiquement supérieurs aux taux TCV, ce qui souligne l'efficacité de la stratégie de la règle de vote dans le système de diagnostic proposé.

3.5.6 Expérience 6 : Système de diagnostic de la maladie de Parkinson basé sur le classificateur GMM en mode dépendant avec le descripteur MFCC

- Cette expérience a pour objectif d'identifier la configuration optimale du classificateur GMM de deuxième système, permettant d'obtenir les meilleurs taux de classification (TCV et TCS) dans le cadre d'un système de diagnostic de la maladie de Parkinson, en mode dépendant. L'optimisation porte principalement sur le nombre de composantes gaussiennes utilisées dans les modèles GMM représentant les deux classes NP et P. Les figures 3.20 et 3.21 présentent respectivement les taux TCV et TCS en fonction de nombre de composantes gaussiennes N_g .




Figure 3.20 : Taux TCV pour classificateur GMM en mode dépendant




Figure 3.21 : Taux TCS pour classificateur GMM en mode dépendant

A partir des figures 3.20 et figure 3.21, nous pouvons donner les remarques suivantes :

- La courbe du taux TCV augmente et atteint approximativement un plateau à partir de Ng égal à 9.
- La courbe du taux TCS augmente et atteint sa valeur maximale de 100% en prenant un nombre de composantes gaussiennes Ng égal à 8. Ensuite, cette courbe présente un plateau avec des fluctuations légères.
- Le taux TCS connaît une augmentation rapide entre Ng = 1 et 2, traduisant une bonne amélioration des performances avec peu de composantes. À partir de Ng = 3, la courbe atteint un palier élevé proche de 100 %, indiquant une excellente stabilité du système sur une large plage de valeurs de Ng.
- Les valeurs de taux TCS sont plus grandes par rapport à celles du taux TCV quelque soit le nombre de composantes gaussiennes Ng. Ce résultat montre l'importance de la stratégie de la règle de vote dans le système de diagnostic de la maladie de Parkinson proposé.

3.5.7 Expérience 7 : Système de diagnostic de la maladie de Parkinson basé sur le classificateur GMM en mode indépendant avec le descripteur PLP

Les courbes TCV et TCS ci-dessous illustrent les performances du système basé sur le classificateur GMM dans un mode indépendant.




Figure 3.21 : Taux TCV pour classificateur GMM en mode indépendant avec le descripteur PLP




Figure 3.22 : Taux TCS pour classificateur GMM en mode indépendant avec le descripteur PLP

A partir des figures 3.21 et figure 3.22 nous pouvons donner les remarques suivantes :

- Le TCV s'améliore nettement entre $N_g = 1$ et $N_g = 5$, atteignant 82.93%. Ensuite, les performances deviennent instables.
- Le TCS s'améliore nettement entre $N_g = 1$ et $N_g = 5$, passant de 69.36% à 87.66%. Après cette progression, les performances deviennent instables. Le meilleur taux (92.77%) est atteint pour $N_g = 11$ et $N_g = 18$. Globalement.

3.5.8 Expérience 8 : Système de diagnostic de la maladie de Parkinson basé sur le classificateur GMM en mode dépendant avec le descripteur PLP

- Cette expérience a pour objectif d'identifier la configuration optimale du classificateur GMM de deuxième système, permettant d'obtenir les meilleurs taux de classification (TCV et TCS) dans le cadre d'un système de diagnostic de la maladie de Parkinson, en mode dépendant. L'optimisation porte principalement sur le nombre de composantes gaussiennes utilisées dans les modèles GMM représentant les deux classes NP et P. Les figures 3.20 et 3.21 présentent respectivement les taux TCV et TCS en fonction de nombre de composantes gaussiennes N_g .




Figure 3.23 : Taux TCV pour classificateur GMM en mode dépendant avec le descripteur PLP




Figure 3.24 : Taux TCS pour classificateur GMM en mode dépendant avec le descripteur PLP

A partir des figures 3.23 et figure 3.24 nous pouvons donner les remarques suivantes :

- Les résultats montrent une amélioration du TCV entre $N_g = 1$ et $N_g = 7$, atteignant plus de 97%. Ensuite, le taux de classification se stabilise, avec des performances très élevées, autour de 97% à 99%.
- Le taux de classification (TCS) s'améliore fortement dès les premières composantes ($N_g = 1$ à 7), atteignant des valeurs très élevées, dépassant les 97%. Le meilleur résultat, atteignant **100%**, est obtenu pour plusieurs valeurs de composantes gaussiennes ($N_g = 19, 21$ et 22), ce qui montre que le modèle devient très performant lorsqu'il dispose d'un nombre suffisant de composantes gaussiennes.

3.6 Conclusion

Dans ce chapitre, nous avons décrit le premier système de diagnostic de la maladie de Parkinson (MP) proposé, reposant sur les modèles HMM associés aux modèles GMM. Également, nous avons décrit le deuxième système basé sur le classificateur GMM combiné avec la stratégie de la règle de vote. Les performances de ces systèmes utilisant les descripteurs MPFCC et PLP sont évalués en utilisant la base de données IPVC en modes dépendant et indépendant. Plusieurs expériences ont été menées afin de répondre à différentes questions liées à la conception de ces systèmes.

Les résultats ont montré que les meilleures performances en mode indépendant du locuteur sont obtenues en utilisant le deuxième système basé sur les modèles GMM de 9 composantes gaussiennes combinés avec le descripteur MFCC. Alors que dans le mode dépendant, les deux systèmes donnent les mêmes performances avec un taux TCS de 100 quelque soit le type de descripteur.

Conclusion Générale

L'analyse automatique du signal vocal appliquée au diagnostic de la maladie de Parkinson vise à détecter, à partir de la parole du patient, des altérations vocales caractéristiques de cette pathologie neurodégénérative. Cette approche s'inscrit dans une dynamique de médecine intelligente et préventive, offrant des perspectives prometteuses, notamment pour le diagnostic précoce, le suivi longitudinal de l'évolution de la maladie, ainsi que l'évaluation de l'efficacité des traitements thérapeutiques.

Dans le cadre de notre travail, nous avons développé et évalué deux systèmes automatiques de diagnostic de la maladie de Parkinson, reposant sur l'extraction de paramètres acoustiques pertinents, tels que les coefficients MFCC et les coefficients PLP. Le premier système utilise le classificateur HMM (Hidden Markov Model), reconnu dans le domaine de la reconnaissance vocale pour sa capacité à modéliser les séquences temporelles et dynamiques des signaux vocaux. Ce modèle, bien qu'exigeant un entraînement plus complexe, permet de mieux représenter la structure temporelle des voix pathologiques.

Le second système s'appuie sur le classificateur GMM (Gaussian Mixture Model), combiné à une stratégie de décision par règle de vote. Cette méthode offre une implémentation plus simple, mais elle se révèle moins efficace que le HMM pour capturer la dynamique temporelle des signaux vocaux.

Les expérimentations ont été conduites en modes dépendant et indépendant du locuteur afin d'évaluer l'impact de cette variable sur les performances des systèmes. Les résultats ont que les deux systèmes fonctionnent efficacement en mode dépendant du locuteur quelque soit le type de descripteur, avec un taux de classification TCS de 100%. En revanche, les performances en mode indépendant ont montré une dégradation notable, mettant en évidence l'importance de l'adaptation au locuteur dans les systèmes de diagnostic vocal. Le premier système, quant à lui a présenté des résultats satisfaisants mais globalement inférieurs à ceux obtenus avec le deuxième système basé sur le classificateur GMM combiné avec le descripteur MFCC. Les résultats confirment la robustesse du deuxième système en utilisant descripteur MFCC en mode indépendant.

Pour approfondir ce travail, plusieurs perspectives peuvent être envisagées :

- L'intégration d'autres types de descripteurs de paramètres acoustiques, tels que le descripteur LPCC (Linear Predictive Cepstral Coefficients) et le descripteur WCC (Wavelet Cepstral Coefficients) basé sur la transformée DWT ;
- L'exploration d'autres classificateurs comme les réseaux de neurones artificiels (ANN), les machines à vecteurs de support (SVM), ou encore les réseaux convolutifs (CNN)

- L'enrichissement de la base de données vocale afin de mieux représenter la diversité inter-individuelle et les différents stades de la maladie.

REFERENCES

REFERENCES

- [1] H. Bengacemi, "L'analyse de signaux EMG et leur application au diagnostic de la maladie de Parkinson," *Thèse de doctorat, Université d'Orléans; École Militaire Polytechnique (Alger)*, 2021, pp. 16–17, NNT : 2021ORLE3121, [Online]. Available: <https://theses.fr/2021ORLE3121>.
- [2] N. Bellil, "Discrimination d'une voix pathologique par la classification Deep-Learning basée images. Etude de Cas : Maladie de Parkinson," *Faculté des Sciences, Département Mathématiques et Informatique*, 2019–2020.
- [3] G. Stern, "Did parkinsonism occur before 1817?," *J. Neurol. Neurosurg. Psychiatry*, 1989, vol. 52, Suppl. 11.
- [4] R. Abdelaziz and Z. Nab, "Système d'aide à la décision pour le diagnostic de la maladie de Parkinson à partir de la voix," *Univ. Saad Dahlab de Blida*, 2014–2015, pp. p. 16.
- [5] N. Dave, "Feature Extraction Methods LPC, PLP and MFCC In Speech Recognition," *G H Patel College of Engineering, Gujarat Technological University*, 2016.
- [6] A. Kumar, "Hidden Markov Models: Concepts, Examples," *Data Analytics*, 2023, [Online]. Available: <https://vitalflux.com/hidden-markov-models-concepts-explained-with-examples/>.
- [7] C. De Stefano, F. Fontanella, D. Impedovo, G. Pirlo, and A. Scotto di Freca, "Handwriting analysis to support neurodegenerative diseases diagnosis: A review," *Elsevier*, 2022.
- [8] M. Aljalal, S. A. Aldosari, M. Molinas, K. AlSharabi, and F. A. Alturki, "Detection of Parkinson's disease from EEG signals using discrete wavelet transform, different entropy measures, and machine learning techniques," *Sensors*, 2021.
- [9] N. H. Ghassemi et al., "Combined accelerometer and EMG analysis to differentiate essential tremor from Parkinson's disease," *Proc. IEEE EMBC*, 2016, pp. 672–675.

- [10] N. Nazmi et al., "A review of classification techniques of EMG signals during isotonic and isometric contractions," *Sensors*, 2016, vol. 16, no. 8, p. 1304.
- [11] V. A. S. B. Kavitha and S. Venkatachalam, "A Novel Gender Recognition in Emotional Environment," *Int. J. Comput. Appl.*, 2015, pp. p. 15, vol. 115.
- [12] O. C. Ibe, "14 - Hidden Markov Models," in *Markov Processes for Stochastic Modeling*, 2nd ed., Oxford: Elsevier, 2013, pp. 417–451.
- [13] A. Makhlouf, "Reconnaissance Automatique de la Parole par les HMM en Milieu Bruité : Contribution par paramétrisation acoustique robuste," *Mémoire Master*, 2016.
- [14] M. G. Di Cesare, D. Perpetuini, D. Cardone, and A. Merla, "Machine Learning-Assisted Speech Analysis for Early Detection of Parkinson's Disease," *IEEE Access*, 2022.
- [15] E. Majda-Zdancewicz et al., "Speech Signal Analysis in Patients with Parkinson's Disease," *Sensors*, 2021.
- [16] A. Aishat, S. Kompalli, "Comparative Study of Speech Analysis Methods to Predict Parkinson's Disease," *Carnegie Mellon Univ.*, 2021.
- [17] T. B. Drissi, S. Zayrit, B. Nsiri, and A. Ammoummou, "Diagnosis of Parkinson's Disease based on Wavelet Transform and MFCC," *Proc. Int. Conf.*, 2021.
- [18] M. A. Sayed et al., "Parkinson's Disease Detection through Vocal Biomarkers and Advanced Machine Learning Algorithms," *Proc. Int. Conf.*, 2021.
- [19] M. Shen, P. Mortezaagha, and A. Rahgozar, "Explainable Artificial Intelligence to Diagnose Early Parkinson's Disease via Voice Analysis," *Proc. IEEE*, 2022.
- [20] H. Bengacemi et al., "Surface EMG Signal Classification for Parkinson's Disease using WCC Descriptor and ANN Classifier," *Proc. Conf.*, 2020.
- [21] Q. Du, J. Shen, P. Wen, and X. Chen, "Parkinson's Disease Detection by Using Machine Learning Method," *Elsevier*, 2021.
- [22] P. Taylor and R. Caley, "The architecture of the Festival speech synthesis system," *Jean*, 1998.

- [23] H. Boulard et al., *"Traitement de la Parole," R. Boite, 2000.*
- [24] Y. Aziza, *"Modélisation AR et ARMA de la parole pour une vérification robuste du locuteur," Mémoire Master, 2013.*
- [25] A. B. Abdusalomov et al., *"Improved Feature Parameter Extraction from Speech Signals Using Machine Learning," Proc. Conf., 2021.*
- [26] Y. Attabi, *"Reconnaissance Automatique des Émotions à partir du Signal Acoustique," Thèse de doctorat, 2008.*
- [27] A. Hacine-Gharbi, *"Sélection de paramètres acoustiques pertinents pour la reconnaissance de la parole," Thèse de doctorat, Univ. Sétif, 2012.*
- [28] N. Zerari, *"Intégration d'un module de reconnaissance de la parole au niveau d'un système audiovisuel," Thèse de doctorat, 2021.*
- [29] S. S. Stevens, J. Volkman, and E. B. Newman, *"A scale for the measurement of the psychological magnitude pitch," J. Acoust. Soc. Am., 1937, pp. 185–190, vol. 8, no. 3.*
- [30] A. Hacine-Gharbi and P. Ravier, *"On the optimal number estimation of selected features using joint histogram based mutual information," J. King Saud Univ., 2021, pp. 1074–1083, vol. 33, no. 9.*
- [31] S. Young, *"The HTK book (HTK version 3.4)," Cambridge Univ. Eng. Dept., 2006.*