

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE  
MINISTRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE  
SCIENTIFIQUE

*Université de Mohamed El-Bachir El-Ibrahimi - Bordj Bou Arreridj*

*Faculté des Sciences et de la technologie*

*Département d'Electronique*

## ***Mémoire***

*Présenté pour obtenir*

**LE DIPLOME DE MASTER**

**FILIERE : Télécommunications**

**Spécialité : Systèmes des Télécommunications**

Par

- Mlle. MAYASSA KHAWLA
- Mlle. BELGUERRA ANSAR CHAIMA
- *Intitulé*

***Diagnostic de la maladie covid-19 basé sur l'analyse du signal vocal et la classification KNN***

***Soutenu le : .....***

***Devant le Jury composé de :***

<b><i>Nom &amp; Prénom</i></b>	<b><i>Grade</i></b>	<b><i>Qualité</i></b>	<b><i>Etablissement</i></b>
<b><i>Mme. HACINI .Latifa M</i></b>	<b><i>Professeur</i></b>	<b><i>Président</i></b>	<b><i>Univ-BBA</i></b>
<b><i>Mr.HACINE GHARBI Abdenour</i></b>	<b><i>MCA</i></b>	<b><i>Encadreur</i></b>	<b><i>Univ-BBA</i></b>
<b><i>Mme. MESSALI .Zoubaida</i></b>	<b><i>MCA</i></b>	<b><i>Examineur</i></b>	<b><i>Univ-BBA</i></b>
<b><i>Mr. Ghazali Fateh</i></b>	<b><i>DR</i></b>	<b><i>Co-encadreur</i></b>	<b><i>Univ-BBA</i></b>
<b><i>Mme Djellal Khawla</i></b>	<b><i>Doctorante</i></b>	<b><i>Co-encadreur</i></b>	<b><i>Univ-BBA</i></b>

***Année Universitaire 2021/2022***

## *Remerciements*

Le présent travail n'est pas seulement le fruit de nos propres efforts, mais aussi les efforts de bien de personnes à qui nous exprimons notre sincère remerciement.

En premier lieu, nous tenons à remercier ALLAH, notre créateur, le tout puissant de nous avoir donné la santé et la volonté d'entamer et de terminer ce mémoire.

On tient à remercier toutes les personnes qui ont contribuées et nous aidés lors de la rédaction de ce mémoire.

Tout d'abord, ce travail ne serait pas aussi riche et n'aurait pas pu avoir le jour sans l'aide et l'encadrement de **Dr. HACINE-GHARBI ABDENOUR**, le directeur de ce mémoire ; on veut s'adresser tous nos remerciements et nos gratitudes pour la qualité de son encadrement exceptionnel, pour sa patience, son aide pratique et sa disponibilité durant notre préparation de ce mémoire, surtout ses judicieux conseils, qui ont contribué à alimenter nos réflexions.

Nos remerciements s'adressent à **DR. GHAZALI FATEH** pour son aide pratique et son soutien moral et ses encouragements.

Nos remerciements s'adressent aussi à **Mme. Djellal Khwla** pour son soutien et ses encouragements.

Nous tenons aussi à exprimer nos remerciements aux membres du jury qui accepté d'évaluer ce modeste travail

On souhaite particulièrement remercier nos amis et collègues qui nous ont apporté leur soutien moral et intellectuel tout au long de nos études.

Enfin, on tient à témoigner toute nos gratitudes à nos familles en général, et surtout nos parents, pour leur amour, leurs conseils ainsi que leur soutien inconditionnel, à la fois moral et économique.

Merci ...

## *Dédicace*

*Je voudrai dédier ce travail à ALLAH tout puissant.*

*Pour celui qui ma enseigné tendre sans attendre, a qui je porte son nom  
fièrement, qui m'a appris et m'a amené ici, qui travaille dur pour mon bonheur,  
je demande a dieu de vous donner longue vie et bonne santé pour tous les  
sacrifices que vous avez consentis pour nous. Mon affectueux père «SACI».*

*Pour mon ange dans la vie...à la signification de l'amour et le sens de la  
compassion et de dévouement...à la bougie qui inspire mon trajet d'étude, pour  
chaque goutte de sueur sur son front orné, au premier mot que mes levers  
disent ma chère maman «NAIMA».*

*Pour les cœurs immaculés âmes et innocent mes frères et sœurs pour leurs  
grand amour et leurs soutien.*

*khawla*

## *Dédicace*

*Je dédie ce modeste travail aux étoiles de ma vie*

*Ma mère et mon père*

*A tous les membres de la famille*

*A toutes mes amies*

*Et à tous ceux qui m'aiment*

*Ansar*

## *Résumé*

Notre travail consiste à concevoir et implémenter un système de diagnostic de la maladie Covid-19 à partir du signal vocal. Ce système est basé sur une architecture récemment appliquée dans plusieurs systèmes de reconnaissance de formes tels que l'identification des appareils électriques, le diagnostic de la maladie de Parkinson et la classification des signaux PCG (phono-cardiau-grammes). Cette architecture consiste à appliquer le classificateur KNN avec la stratégie de la règle de vote. Plus particulièrement, notre système de diagnostic proposé se base sur l'extraction des paramètres acoustiques MFCC et LPCC, combinée avec le classificateur KNN et la stratégie de la règle de vote. Ce système est évalué sous une base de données constituée de 600 signaux vocaux appartenant à trois classes différentes notées par: H (Healthy), S (présentant des symptômes différents de covid19) et C (présence de la maladie Covid19). Les résultats de différentes expériences cherchant la bonne configuration du système nous ont montré de performances acceptables avec un taux de classification de 63.67% obtenu en choisissant le type de paramètres MFCC et le classificateur KNN basé sur la distance "Corrélation" avec un nombre de vecteurs les plus proches voisins égal à 8.

**Mots clés:** Diagnostic de la maladie Covid-19, classificateur KNN, règle de vote, analyse du signal vocal, paramètres MFCC, paramètres LPCC.

## *Abstract*

Our work consists in designing and implementing a diagnostic system for Covid-19 from the speech signal. This system based on an architecture recently applied in several pattern recognition systems such as the electrical appliances identification, the diagnosis of Parkinson's and the classification of PCG (phono-cardiau-grams) signals. This architecture consists in applying standard classifiers with the voting rule strategy. More specifically, our proposed diagnostic system is based on the extraction of MFCC and LPCC acoustics features, combined with the KNN classifier and the voting rule strategy. This system is evaluated under a database consisting of 600 voice signals belonging to three different classes denoted by: H (Healthy), S (presenting different symptoms of covid19) and C (presence of Covid19). The results of various experiments seeking the correct configuration of the system showed us acceptable performance with a classification rate of 63.67 % obtained by choosing the type of parameters MFCC and the classifier KNN based on the distance "Correlation" with a number of nearest neighbor vectors equal to 8.

**Keywords:** Covid-19 disease diagnosis, KNN classifier, voting rule, vocal signal analysis, MFCC features, LPCC features.

## ملخص

يتمثل عملنا في تصميم وتنفيذ نظام تشخيص لمرض Covid-19 من إشارة الكلام. يعتمد هذا النظام على بنية تم تطبيقها مؤخرًا في العديد من أنظمة التعرف على الأنماط مثل تحديد الأجهزة الكهربائية وتشخيص مرض باركنسون وتصنيف إشارات PCG (فونو كارديو جرام). تتكون هذه البنية من تطبيق المصنفات القياسية مع إستراتيجية قاعدة التصويت. وبشكل أكثر تحديدًا ، يعتمد نظام التشخيص المقترح لدينا على استخراج الميزات الصوتية MFCC او LPCC ، بالتنسيق مع مصنف KNN واستراتيجية قاعدة التصويت . يتم تقييم هذا النظام على قاعدة بيانات تتكون من 600 إشارة صوتية تنتمي إلى ثلاث فئات مختلفة يُشار إليها بـ: H (صحي) و S (تظهر أعراض مختلفة لـ covid19) و C (وجود مرض Covid19). أظهرت نتائج التجارب المختلفة التي تسعى إلى التكوين الصحيح للنظام أداءً مقبولاً بنسبة تصنيف 63.67% متحصل عليها باختيار الميزات الصوتية MFCC مع المصنف KNN اعتماداً على المسافة ( "corrélation" و عدد الأعمدة الأقرب يساوي 8. تؤكد هذه النتائج صحة مفهوم استخدام تحليل الإشارات الصوتية للمهمة التشخيصية لمرض Covid19.

**الكلمات المفتاحية :** تشخيص مرض كوفيد-19 ، مصنف KNN ، قاعدة التصويت ، تحليل إشارة الكلام ، الميزات MFCC, الميزات LPCC.

## *Sommaire :*

Liste des tableaux	
Liste des figures	
Introduction générale .....	1
Chapitre I : Etat de l'art sur le diagnostic de la maladie 'covid 19'	
I.1. Introduction.....	3
I.2. Historique .....	3
I.3. Définition.....	3
I.4. Les type de coronavirus.....	4
I.5. Transmission et prévention.....	5
I.6. Symptômes de la maladie Covid-19.....	5
I.7. Modalités de diagnostic.....	5
I.7.1. Test d'acide d'amplification nucléique (RT-PCR).....	6
I.7.2. La Tomodensitométrie (TDM).....	6
I.7.3. Radiographie thoracique (CXR).....	6
I.7.4. Sons respiratoires humains.....	7
I.8. Système de diagnostic de la maladie covid-19 basé sur l'analyse du signal vocal.....	8
I.8.1. Principe de fonctionnement d'un système de diagnostic de la maladie COVID....	8
I.8.2. Extraction de paramètre.....	9
I.8.2.1. Prétraitement.....	9
I.8.2.2 fenêtrage et formation de trames.....	9
I.8.2.3 Analyse à court terme.....	9
I.9 Classification.....	10
I.9.1 KNN (K-Nearest Neighbor).....	10
I.9.1.1 Définition.....	10
I.9.1.2. Algorithme de classification KNN.....	10
I.9.1.3 Configuration de classification KNN.....	11
I.9.1.3.1 Distance Euclidienne.....	11
I.9.1.3.2 Distance Cosinus.....	11
I.9.1.3.3 Distance de Cityblock.....	11
I.9.1.3.4 Distance corrélation.....	12
I.10 La règle de vote.....	12
I.11 Conclusion.....	12
Chapitre II : Analyse du signal vocal pour la diagnostique de la maladie covid-19	
II.1 Introduction.....	13
II.2 Définition du signal de parole.....	13
II.3 Paramètres du signal de parole.....	13
II.4 traitement de la parole.....	14
II.5. Extraction de paramètres.....	14
II.5.1 Coefficients cepstraux sur l'échelle Mel (MFCC).....	15
II.5.1.1 Étape s de calcul du vecteur de paramètres MFCC .....	15
II.5.1.1.1 Segmentation en trames.....	16

II.5.1.1.2 Fenêtrage de Hamming.....	16
II.5.1.1.3 Calcul de la transformée de Fourier rapide (Fast Fourier Transforme FFT) .....	16
II.5.1.1.4 Filtrage e sur l'échelle Mel.....	16
II.5.1.1.5 Calcul du cepstre sur l'échellMel.....	17
II.5.1.1.6 Calcul des paramètres dynamiques des MFCC.....	17
II.5.2 Code à prédiction linéaire (LPC).....	17
II.5.3 coefficients cepstraux de prédiction linéaire (LPCC).....	18
II.6 Etat de l'art sur l'analyse du signal vocal appliquée au diagnostic de covid-19.....	19
II.7 conclusion.....	20
Chapitre III : Implémentation du système de diagnostic de la maladie COVID-19	
III.1. Introduction.....	21
III.2 Etape de préparation de la base de données.....	22
III.3 DESCRIPTION DES ETAPES D'IMPLEMENTATION DU SYSTEME PROPOSE	
III.3.1 Phase d'apprentissage.....	23
III.3.1.1 Extraction des paramètres MFCC .....	24
III.3.1.2 Extraction des paramètres LPCC.....	25
III.3.2 Phase de test.....	26
III.4. Expériences et résultats.....	26
III.4.1 Paramètres optimaux du classificateur KNN .....	27
III.4.1.1 Paramètres optimaux du classificateur KNN combiné avec la méthode d'extraction des paramètres MFCC.....	27
III.4.1.2 Paramètres optimaux du classificateur KNN combiné avec la méthode d'extraction des paramètres LPCC.....	29
III.4.2 Meilleur descripteur des paramètres MFCC .....	30
III.4.3 Effet de la réduction de la dimensionnalité des vecteurs de paramètres MFCC sur les performances du système.....	31
III.4.4 Effet de la fréquence d'échantillonnage les performances du système.....	32
III.5. Conclusion.....	33
Conclusion générale.....	36

## *Liste des tableaux*

<b>Tableaux II-1</b> : Etat de l'art sur l'analyse du signal vocal appliquée au diagnostic de covid-19 .....	19
<b>Tableau III -1</b> : Fichier de configuration (config.txt) de l'étape d'extraction des paramètres MFCC.....	24
<b>Tableau III -2</b> : Fichier de configuration (config.txt) de l'étape d'extraction des paramètres LPCC.....	25
<b>Tableau III-3</b> : Taux de classification TCS pour les quinze premières valeurs de k correspondant à chaque distance, en utilisant les paramètres MFCC.....	28
<b>Tableau III-4</b> : Taux de classification maximal et k optimal correspondant à chaque distance en utilisant les paramètres MFCC.....	28
<b>Tableau III-5</b> : Taux de classification TCS pour les quinze premières valeurs de k correspondant à chaque distance, en utilisant les paramètres LPCC.....	30
<b>Tableau III-6</b> : Taux de classification maximal et k optimal correspondant à chaque distance en utilisant les paramètres LPCC.....	30
<b>Tableau III-7</b> : Taux de classification TCV et TCS pour les différents descripteurs : MFCC, E et leurs paramètres dynamiques.....	31
<b>Tableau III-8</b> : Taux de classification TCS en fonction de la fréquence d'échantillonnage $f_s$ .....	33

## *Liste des figures*

<b>Figure I-1</b> : Taux d'utilisation de différentes modalités radiologiques dans le diagnostique du COVID-19 .....	6
<b>Figure I-2</b> : Résultats de radiographie pulmonaire chez un patient atteint de maladie à coronavirus. (A) Consolidations inégales, (B) épanchement pleural, (C) distribution péri-hilaire, (D) distribution périphérique.....	7
<b>Figure I-3</b> : Schéma synoptique du système diagnostique de la maladie covid-19 .....	8
<b>Figure I-4</b> : <i>Étapes d'extraction de paramètres</i> .....	9
<b>Figure II-1</b> : Fonctions du traitement de la parole.....	14
<b>Figure II-2</b> : Étapes de calcul d'un vecteur de caractéristiques de type MFCC.....	15
<b>Figure II-3</b> : Schéma fonctionnel du processeur LPCC .....	18
<b>Figure III-1</b> : Etapes de conception du système de diagnostic de la maladie Covid-19, basé sur le classificateur KNN et la règle de vote .....	23
<b>Figure III.2</b> : Evolution du TCS en fonction de la valeur de k pour les différentes distances, en utilisant les paramètres MFCC.....	28
<b>Figure III.3</b> : Evolution du TCS en fonction de la valeur de k pour les différentes distances, en utilisant les paramètres LPCC.....	29
<b>Figure III.4</b> : Evolution du TCS en fonction du nombre de paramètres MFCC.....	32

## *Liste des abréviations*

**LeSRAS-CoV** : Syndrome Respiratoire Aigu Sévère

**Le MERS-CoV**: Middle East Respiratory Syndrome

**SARS-CoV-2** : Coronavirus 2 du Syndrome Respiratoire Aigu Sévère

**COVID-1** : Maladie de Coronavirus 2019

**RT-PCR** : Test d'Acide d'Amplification Nucléique

**LPCC**: Linear Prediction Cepstrum Coefficients

**MFCC**: Mel-Frequency Cepstral Coefficients

**HKU1** : Bêta-Coronavirus

**OMS**: Organisation Mondiale de la Santé

**229E** : Alpha Coronavirus

**NL63** : Alpha Coronavirus

**OC43** : Bêta-Coronavirus

**ARN** : Acide Ribonucléique

**TDM** : Tomodensitométrie

**CXR** : Chest X-Ray (Radiographie aux Rayons X)

**FFT**: Fast Fourier Transforme.

**LPC**: Linear Predictive Coding

**KNN**: k-Nearest Neighbors

**ANN**: Artificial Neural Network

**GSM**: Global System for Mobil

**HMM**: Hidden Markov Model

**GMM**: Gaussian Mixtures Model.

**SVM**: Support Vector Machine

## Introduction générale

La maladie COVID-19 est une maladie infectieuse, connue par coronavirus et par pandémie de COVID-19. L'histoire de cette pandémie commence en décembre 2019, dans la ville de Wuhan en Chine. Jour après jour, elle se propage rapidement dans la Chine. Ensuite, elle s'est étendue dans le monde entier. Ce virus cause des conséquences catastrophiques dans le monde sur le côté sociale et le côté de santé ainsi que sur le côté économique (le confinement a brutalement mis à l'arrêt des activités humaines et économiques). Le COVID-19 est une nouvelle maladie infectieuse respiratoire très contagieuse par le contact avec une personne infectée ou par les gouttelettes respiratoires, les éternuements et la toux ou par aérosol contenant le virus, et aussi lorsque la distance est faible entre la personne infectée et les autres où l'espace est fermé.

La détection des patients atteints de coronavirus (COVID-19) est désormais une tâche critique pour le médecin car il se propage très rapidement entre les personnes et touche des millions de personnes dans le monde et avec l'apparition des nouveaux types de COVID-19 jours après jours, on trouve parfois la présence des symptômes de COVID-19 et parfois leur absence. En conséquence, il est très essentiel d'identifier rapidement les personnes infectées pour empêcher une telle propagation du virus. Il existe différentes modalités pour tester la présence de COVID-19 dans le corps humain, notamment les plus utilisées comme les tests RT-PCR, les tests antigéniques et les tests sérologiques.

Aujourd'hui, des équipes de recherche sont en mesure de créer des algorithmes en intelligence artificielle, permettant d'effectuer un diagnostic de cette maladie, à la fois plus rapide et plus fiable que celui de l'être humain. Ces algorithmes s'appliquent généralement sur différentes modalités telles que : l'image médicale (scanner, IRM,...), l'analyse du signal vocal, etc....

Dans le présent travail, nous proposons un système de diagnostic de la maladie COVID-19 basé sur l'analyse du signal vocal combinée avec l'algorithme de classification KNN et la stratégie de règle de vote. En fait, cette stratégie de classification KNN avec la règle de vote est récemment proposée dans plusieurs travaux de recherche tels que l'identification des appareils électriques [1], le diagnostic de la maladie de Parkinson [2] et la classification des signaux Phono-cardiogramme (PCG) [3].

La conception d'un tel système se base sur une phase d'apprentissage pour apprendre les modèles de classes considérées et une phase de test pour identifier la classe de chaque signal

d'entrée et d'évaluer les performances du système. Ces deux phases exigent une étape d'extraction de paramètres permettant de convertir chaque signal en une séquence de vecteurs de paramètres. Dans notre travail, on s'intéresse à utiliser la méthode d'extraction des paramètres MFCC qui est couramment appliquée dans le traitement du signal vocal, ainsi que les paramètres LPCC. Chaque vecteur de paramètres est constitué des paramètres MFCC/LPCC statiques, de l'énergie ainsi que de leurs paramètres dynamiques  $\Delta$  et  $\Delta\Delta$ . L'étape classification du signal vocal consiste premièrement à appliquer le classificateur KNN sur chaque vecteur de la séquence, ensuite appliquer la règle de vote sur la séquence d'indices de classes afin d'obtenir la classe la plus votée représentant la classe du signal d'entrée. L'évaluation des performances s'effectue en termes du taux de classification des signaux sous une base de données de 600 signaux de courtes durées appartenant à trois classes notées par H (Healthy), S (présence de symptômes non-covid-19) et C (présence du Covid-19). Cette base est extraite d'une base de données publique.

Ce manuscrit est organisé en trois chapitres décrits comme suit :

Le chapitre I sera consacré à un état de l'art sur le diagnostic de la maladie Covid-19. Un historique sur cette maladie sera présenté. De plus, le principe général de fonctionnement d'un système de diagnostic sera décrit.

Le Chapitre II donne un aperçu sur les méthodes d'analyse du signal vocal. Plus particulièrement, l'extraction des paramètres MFCC et LPCC seront décrites.

Le chapitre III sera consacré à la conception et l'implémentation du système proposé, ainsi qu'à la présentation des différentes expériences et discussion des résultats.

Finalement, nous terminons par une conclusion générale et des perspectives.

# **Chapitre I : Etat de l'art sur le diagnostic de la maladie 'COVID 19'**

## I.1 Introduction

Le monde a connu ces dernières années, une nouvelle maladie à grande échelle de type pneumonie, causée par la propagation énorme d'un virus très actif, appelé coronavirus (COVID-19). Ce virus est apparu pour la première fois à Wuhan, en Chine, à la fin de l'année 2019, une année plus tard le virus est propagé sur le monde entier. Il est déclaré pandémie par l'organisation mondiale de la santé en mars 2020. Pour l'instant, il y a plus de 600 millions de cas confirmés infectés par le COVID-19 dans plus de 200 pays. L'organisation mondiale de suivi de corona virus dans le monde déclare que plus de 6,5 million de personnes décédées après avoir été infectées par ce virus en 2022. Le nouveau coronavirus suscite un intérêt généralisé en raison de son diffusion rapides et son impact vital sur les personnes dont le système immunitaire est faible [4].

## I.2 Historique

En décembre 2019, une épidémie de pneumonies d'allure virale « inconnue » a été décelée dans la ville de Wuhan en chine. Près de 59 cas de pneumonies ont été signalés en chine, entre le 12 et 29 décembre 2019. Le 9 janvier, la découverte d'un nouveau coronavirus (d'abord appelé COVID-19), puis officiellement SARS-CoV-2, est annoncé par les autorités sanitaires chinoises et l'OMS. Le 9 janvier, les autorités sanitaires chinoises et l'OMS ont annoncé officiellement la découverte d'un nouveau coronavirus (d'abord appelé COVID-19, puis SARS-CoV-2), considéré comme responsable de la nouvelle maladie infectieuse respiratoire.

La propagation du virus a causé l'infection près de 4400 personnes en 27 janvier, dont une quarantaine à l'étranger dans 18 pays différents (provoquant 107 morts). Tous les pays de l'Union européenne étaient contaminés par ce virus au 10 mars 2020. Plus de 152 898 cas d'infection sont dénombrés dans 137 pays en 14 mars 2020. Le virus suit une croissance exponentielle provoquant plus de 38 000 morts au 31 mars 2020 [5]. Jusqu'au 19 juin 2022, le nombre total de cas confirmé est de plus 600 millions de cas avec plus de 6 millions de décès.

## I.3 Définition

Le 11 février 2020, l'OMS a donné le nom Covid-19 à une nouvelle maladie infectieuse respiratoire apparue en décembre 2019, en Chine, et causée par le coronavirus SARS-CoV-2.

L'abréviation du nom Covid-19 est expliquée comme suit :

- "Co" pour "corona",

- "vi" pour "virus"
- "D" pour "disease" ("maladie" en anglais).
- 19 pour l'année de son apparition : 2019.

Les coronavirus sont des maladies respiratoires très contagieuses propagent dans tout le monde rapidement dans un peu de temps avec des risques de mortalité élevés pour certaines personnes. Leur nom signifie « **virus en couronne** » et vient du fait qu'ils possèdent tous un aspect en forme de couronne lorsqu'ils sont observés au microscope. Ces virus à ARN peuvent infecter aussi bien l'homme que l'animal, possèdent un taux de mutation élevé à l'instar de celui de la grippe ou du virus VIH. Les coronavirus sont aussi zoonotiques, c'est-à-dire qu'ils se transmettent de l'animal à l'homme. Des enquêtes détaillées ont révélé que le SARS-CoV se transmettait de la civette, un petit mammifère, à l'homme et le MERS-CoV du dromadaire à l'homme. On connaît plusieurs coronavirus qui circulent chez certains animaux, mais qui n'ont pas encore infecté l'homme [6].

Chez l'homme, les manifestations de l'infection vont du simple rhume à une infection pulmonaire sévère, responsable d'une détresse respiratoire aiguë. Les coronavirus ont été identifiés pour la première fois chez l'humain dans les années 1960.

## I.4 Type de coronavirus

Quatre sous-groupes de coronavirus sont moins graves que les autres: alpha beta, gamma et delta (moins graves que les autres) :

- 229E (alpha coronavirus)
- NL63 (alpha coronavirus)
- OC43 (bêta-coronavirus)
- HKU1 (bêta-coronavirus) [7]

Et trois coronavirus plus grave ont causé des épidémies graves:

- Le SRAS-CoV (pour syndrome respiratoire aigu sévère), responsable d'une épidémie mondiale entre novembre 2002 et juillet 2003,
- Le MERS-CoV (pour Middle East respiratory syndrome), découvert pour la première fois en 2012 au Moyen-Orient.
- Le SRAS-CoV-2, à l'origine responsable de la première pandémie liée à un coronavirus en décembre 2019.[6]

## I.5 Transmission et prévention

La transmission peut être causée essentiellement par :

- Contacts rapprochés : le contact direct avec un objet ou avec une personne infectée.
- Aérosols contenant le virus.
- Les gouttelettes respiratoires, les éternuements et la toux.

Pour réduire son risque d'infection par un coronavirus, il est conseillé de :

- Se laver les mains régulièrement avec de l'eau et du savon (sans oublier les solutions hydro-alcooliques très pratiques quand on ne peut pas se laver les mains).
- Eviter les contacts avec des personnes malades.
- Porter un masque.
- Conserver une distance d'au moins 1.5 mètre avec tout interlocuteur.[7]

## I.6 Symptômes de la maladie Covid-19

Parmi les symptômes de cette maladie, on peut citer :

- La fièvre, la toux, le nez qui coule, une fatigue intense, des douleurs musculaires ou corporelle, diarrhée, Gorge irritée, perte de goût ou d'odorat, une sensation d'oppression ou d'essoufflement et des difficultés respiratoires
- Dans les cas plus graves, l'infection peut provoquer une pneumonie, un syndrome respiratoire aigu sévère, une insuffisance rénale et même la mort.
- Certains patients présentent également une forme asymptomatique du virus : ils sont porteurs du virus, mais ne présentent pas de symptômes[6].

## I.7 Modalités de diagnostic

La détection précoce de la COVID-19 est essentielle non seulement pour les soins aux patients, mais aussi pour la santé publique en assurant l'isolement des patients et en contrôlant la pandémie. En raison de la nouveauté de la maladie, les moyens de la combattre n'étaient pas connus dans les premiers jours, mais les chercheurs ont considéré le dépistage et le diagnostic rapide des patients infectés et leur séparation de la communauté des personnes en bonne santé comme une mesure importante [8].

Depuis l'apparition du COVID-19, divers efforts ont été déployés pour développer des solutions efficaces de diagnostic automatique qui compléteraient les méthodes de test

standard. Alors Nous avons donc de nombreuses façons de diagnostiquer la maladie COVID-19.

### I.7.1 Test d'acide d'amplification nucléique (RT-PCR)

Le test de réaction en chaîne de la polymérase quantitative par transcription inverse en temps réel (RT-PCR) sert de référence pour la détection du COVID-19, il nécessite une visite en personne à l'hôpital ou au laboratoire pour prélever un échantillon des voies respiratoires supérieures (nasopharyngé et oropharyngé). Écouvillon)[9].

### I.7.2 La Tomodensitométrie (TDM)

L'un des moyens les plus importants de diagnostiquer le COVID-19 consiste à utiliser des images radiologiques, y compris des rayons X et une tomodensitométrie (TDM). La TDM thoracique connu sous le nom de scan CT (computed tomography), elle est considérée comme la principale modalité de diagnostic pour examiner les patients atteints de COVID-19. Un grand nombre d'études existantes ont étudié les manifestations d'image CT (computed tomography) dans les cas de COVID-19. L'imagerie thoracique est une procédure simple et rapide recommandée par les protocoles médico-sanitaires et a été mentionnée dans plusieurs textes comme le premier outil de dépistage lors de l'épidémie [8].

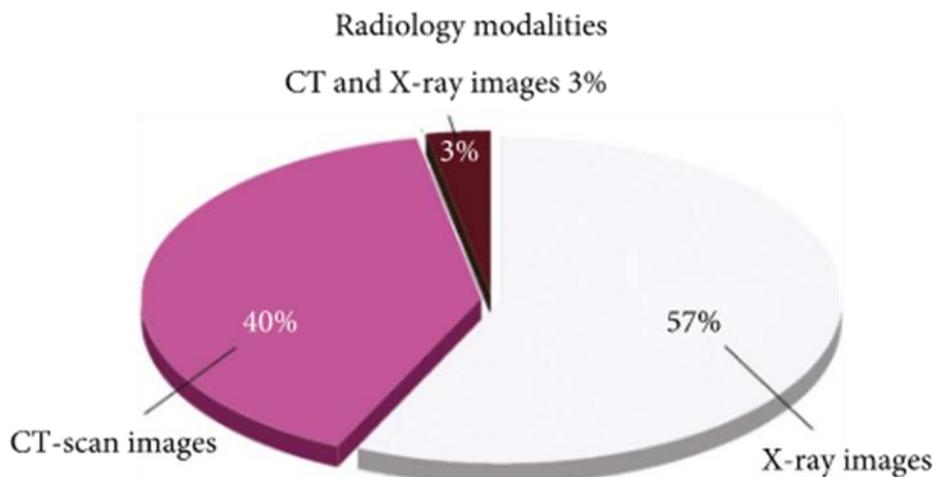
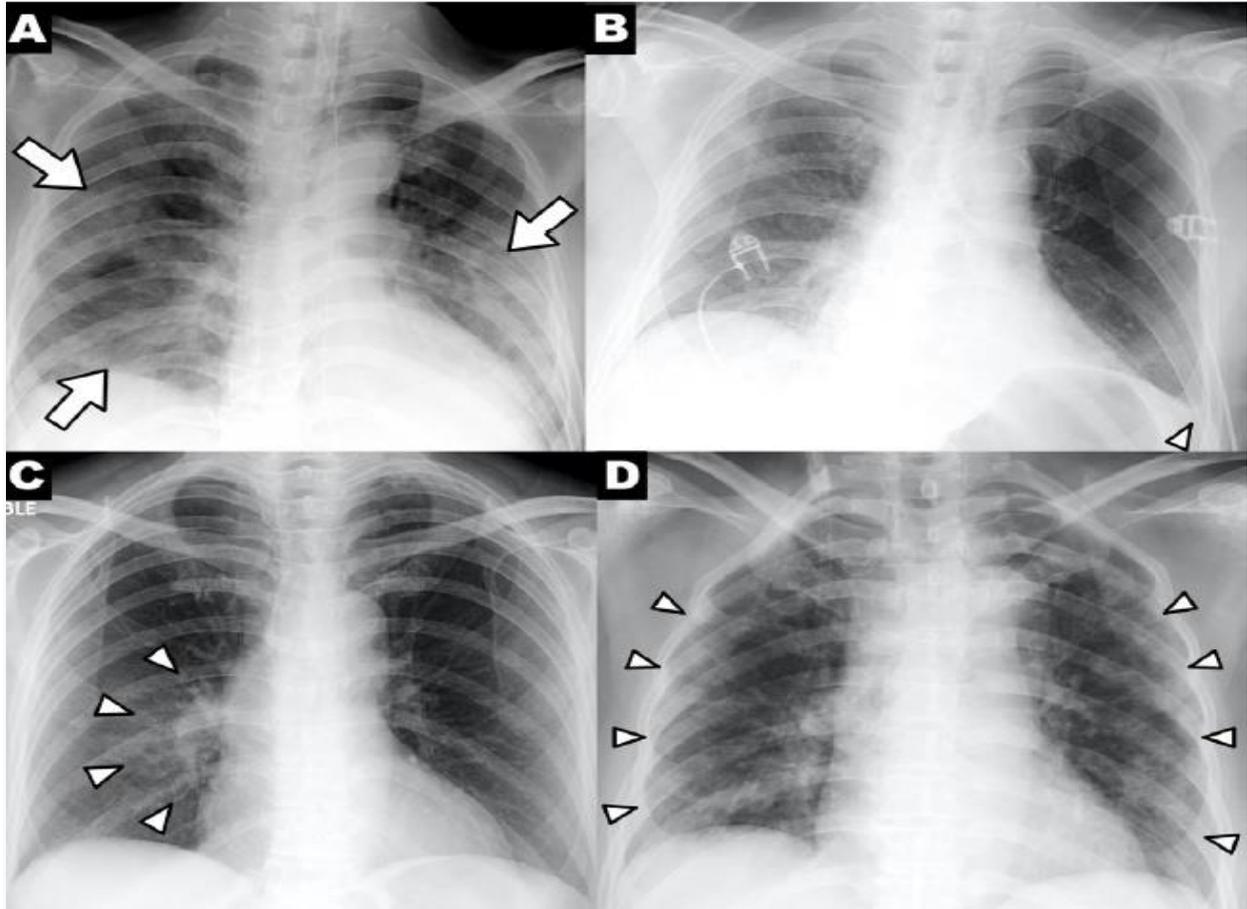


Figure I-1 : Taux d'utilisation de différentes modalités radiologiques dans le diagnostic du COVID-19 [6]

### I.7.3 Radiographie aux rayons X (chest X-ray (CXR))

La CXR est une modalité facilement accessible et peu coûteuse dans la majorité des milieux cliniques. Elle est utilisée pour le triage des personnes soupçonnées d'être atteintes de

la COVID-19 au service des urgences. L'opacification brumeuse prédominante périphérique, la consolidation bilatérale du lobe inférieur et les opacités de l'espace Aérien similaires au syndrome de détresse respiratoire aiguë sont les résultats caractéristiques de la COVID-19 sur CXR. L'épanchement pleural, les nodules et le pneumothorax sont également des résultats inhabituels qui peuvent être discernés chez les patients atteints de COVID-19 [10].



**Figure I-2 :** Résultats de radiographie pulmonaire chez un patient atteint de maladie à coronavirus. (A) Consolidations inégales, (B) épanchement pleural, (C) distribution péri hilare, (D) distribution périphérique[6].

#### I.7.4 Sons respiratoires humains

Les sons respiratoires humains peuvent être obtenus par un stéthoscope électronique / numérique, le modèle présenté est applicable et démontre une robustesse favorable. Des recherches récentes ont commencé à étudier comment les sons respiratoires enregistrés par les appareils intelligents des patients confirmés comme cas positifs de COVID-19 [6]. Les données du stéthoscope numérique d'auscultation pulmonaire peuvent être utilisées pour le diagnostic de la maladie COVID-19. Afin de classer automatiquement l'état de santé des

patients et d'analyser les signaux sonores respiratoires des patients atteints de COVID-19 chez les patients cliniques [6].

## I.8 Système de diagnostic de la maladie covid-19 basé sur l'analyse du signal vocal

### I.8.1 Principe de fonctionnement d'un système de diagnostic de la maladie COVID-19

Récemment, le signal vocal de toux a été utilisé pour le diagnostic de la maladie COVID-19. La base de données utilisée dans cette étude appelée « Coswara » composée des sons respiratoires sains et malsains (y compris celles atteintes de la COVID-19)[11]. Dans notre travail, nous allons utiliser le signal vocal comme modalité pour la conception d'un système diagnostique de la maladie Covid-19. Un tel système de diagnostic peut être considéré comme un système de reconnaissance de formes qui exige une étape d'extraction de paramètres et une étape de classification pour reconnaître la classe du signal d'entrée. Le schéma synoptique standard d'un système de diagnostic de la maladie Covid-19 basé sur la modalité du signal vocal est illustré sur la figure I-3.

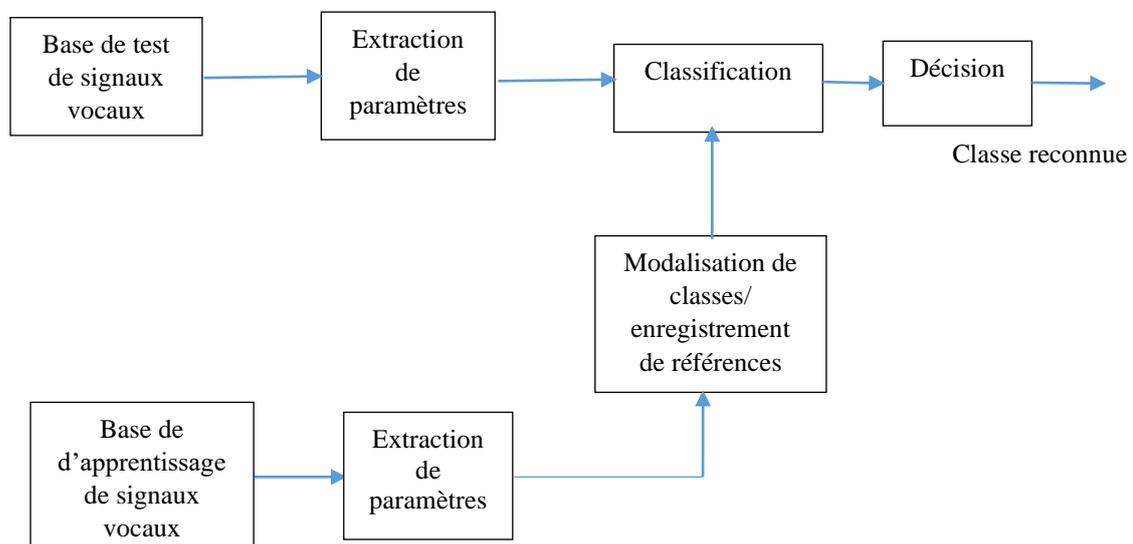


Figure I-3 : Schéma synoptique du système diagnostique de la maladie covid-19

Le fonctionnement d'un système de reconnaissance se base sur deux phases, une phase d'apprentissage pour apprendre les différents modèles de classes (ou enregistrer des références), et une phase de test pour reconnaître et évaluer les performances du système

utilisant un des classificateurs standard tels que : KNN, GMM, HMM, ANN, SVM...etc. Ces deux phases exigent une étape d'extraction de paramètres qui se base sur l'analyse du signal vocal pour extraire des paramètres acoustiques tels que les paramètres MFCC, PLP, LPC, LPCC,...etc.

### I.8.2 Extraction de paramètres

L'extraction de paramètres consiste à convertir chaque signal en une séquence de vecteurs de paramètres. Cette étape d'extraction est réalisée en plusieurs étapes secondaires à savoir : le prétraitement, segmentation en trames, le fenêtrage de Hamming, l'analyse à court terme. La figure I-4 illustre les différentes étapes d'extraction de paramètres.

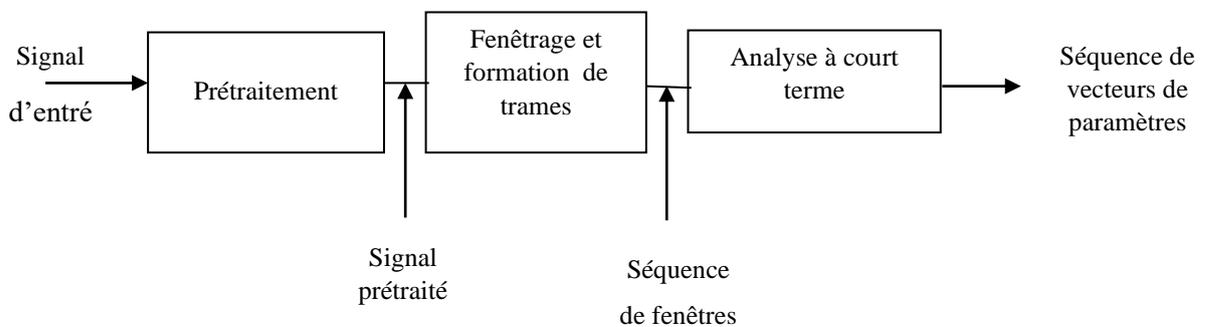


Figure I-4 : Étapes d'extraction de paramètres

#### I.8.2.1 Prétraitement

Cette étape consiste à mettre les signaux sous une forme plus adaptée à l'analyse, en détectant les débuts et les fins de fonctionnement, ainsi que, en éliminant tout éventuels bruit.

#### I.8.2.2 Fenêtrage et formation de trames

Cette étape consiste à découper le signal en fenêtres chevauchées à fin de converti chaque signal en une séquence de vecteurs.

#### I.8.2.3 Analyse à court terme

Cette étape d'analyse à pour objectif de convertir chaque fenêtre instantanée à un vecteur de paramètres (caractéristiques). Dans notre travail, on s'intéresse à extraire les coefficients MFCC et LPCC utilisés souvent dans le domaine de traitement de la parole.

## I.9 Classification

La classification est une tâche importante pour le diagnostic de la maladie COVID-19. Il existe de nombreuses méthodes de classification, on peut citer : **GMM** (Gaussian Mixture Models), **HMM** (Hidden Markov Model), **SVM** (Support Vector Machines), **KNN** (K-NearestNeighbor),...etc. Dans notre travail, on s'intéresse d'utiliser le classificateur KNN pour sa simplicité.

### I.9.1 KNN (K-Nearest Neighbor)

KNN (K-Nearest Neighbor) est une technique utile et rapide utilisée couramment dans la classification des données (signaux, images, texte,...) et plus particulièrement dans le domaine du biomédical. Par conséquent, il est souhaitable de classifier et d'évaluer le COVID-19, en particulier dans la région épidémique pour faire gagner un temps précieux aux professionnels de la santé [12][36].

#### I.9.1.1 Définition

L'algorithme des k les plus proches voisins (« k-nearestneighbors » ou kNN) est un algorithme de classification supervisée qui consiste à comparer un vecteur de paramètres de test à un ensemble de vecteurs de paramètres (références), préalablement enregistré durant la phase d'apprentissage, dans le but de lui affecter une classe en termes de distances . La classe affectée est la classe la plus votée parmi les classes des k vecteurs les proches voisins au vecteur considéré, obtenues dans l'étape de comparaison [12][36].

#### I.9.1.2 Algorithme de classification KNN

Les différentes étapes de l'algorithme KNN pour la classification des vecteurs de paramètres sont données comme suit:

##### *Début Algorithme*

Les données d'entrée sont:

- Un ensemble de données (base de données).
- Une fonction pour la définition de la distance.
- Un nombre entier k.

La prédiction de la classe du vecteur de paramètres de test s'effectue comme suit :

1. Calculer toutes les distances de ce vecteur avec les vecteurs de références de la base de données d'apprentissage.
2. Retenir les k vecteurs de la base de données les proches en appliquant la fonction de calcul de distance.
3. Prendre les valeurs des classes de vecteurs retenues.
4. Retourner la classe la plus la plus votée. [12].

**Fin Algorithme**

### **I.9.1.3 Configuration de classification KNN**

Les performances du classificateur KNN dépend généralement de la valeur de K et du choix de la fonction de distance. La valeur optimale de K peut être obtenue en cherchant parmi un ensemble de valeurs K, celle permettant d'obtenir de meilleures performances évaluées sur une base de données de test.

Le choix de la distance optimale consiste également à chercher parmi un ensemble de fonctions de distances, celle permettant d'obtenir de meilleures performances. Les différentes fonctions distances seront décrites dans les sous sections suivantes :

#### **I.9.1.3.1 Distance Euclidienne**

La distance Euclidienne  $d_E$  est une distance simple et efficace. La distance  $d_E$  entre deux vecteurs X et Y est donnée par :  $(x_i - y_i)^2$

$$d_E(X, Y) = \sqrt{\sum_{i=1}^m (X_i - Y_i)^2} \quad (I.1)$$

#### **I.9.1.3.2 Distance Cosinus**

La distance cosinus  $d_{cos}$ , appelée distance angulaire, est définie comme suit :

$$d_{cos}(X, Y) = 1 - \frac{\sum_{i=1}^m x_i y_i}{\sqrt{\sum_{i=1}^m x_i^2} \sqrt{\sum_{i=1}^m y_i^2}} \quad (I.2)$$

#### **I.9.1.3.3 Distance de Cityblock**

La distance Citybloc  $d_{CIT}$  est définie comme suit :

$$d_{CIT}(X, Y) = \sum_{i=1}^m |x_i - y_i| \quad (I.3)$$

#### I.9.1.3.4 Distance corrélation

La distance Corrélation  $d_{COR}$  entre deux vecteurs  $X$  et  $Y$  est donnée par :

$$d_{COR}(X, Y) = 1 - \frac{\sum_{i=1}^m (x_i - \bar{y}_1)}{\sqrt{\sum_{i=1}^m (x_i - \bar{y}_1)^2}} \frac{(x_i - \bar{y}_1)}{\sqrt{\sum_{i=1}^m (x_i - \bar{y}_1)^2}} \quad (I.4)$$

### I.10 La règle de vote

Dans notre travail, le classificateur KNN a pour objectif de classifier chaque vecteur de paramètres en une classe. Ainsi, chaque séquence de vecteurs de paramètres représentant un signal de test sera convertie en une séquence d'indices de classes en appliquant l'algorithme de classification KNN. La stratégie de règle sera appliquée sur la séquence d'indices de classes obtenue pour chercher la classe la plus votée qui sera considérée comme la classe du signal de test. Cette stratégie permet ainsi de prendre une décision sur la classification de signal de test.

Dans notre travail, le système de diagnostic de la maladie Covid-19 à concevoir se base sur l'analyse du signal vocal et la combinaison du classificateur KNN avec la stratégie de la règle de voté.

### I.11 Conclusion

Dans ce chapitre, nous avons présenté un état de l'art sur le diagnostic de la maladie 'COVID 19', ainsi que les différentes modalités de diagnostic. Parmi ses diagnostics, on a étudié le diagnostic de la maladie covid-19 basé sur l'analyse du signal vocal ainsi que son principe de fonctionnement. On a présenté également les deux phases essentielles, chaque phase exige une étape d'extraction de paramètres, La première phase appelée phase d'apprentissage a pour objectif de modéliser les différentes classes (ou enregistrement de références), alors que la phase de test se base sur une étape d'extraction et une étape de classification pour mesurer les performances du système de diagnostic. De plus, on a parlé brièvement sur l'étape d'extraction de paramètres ainsi que les techniques de classifications. Plus particulièrement, on a décrit le fonctionnement du classificateur KNN et sa combinaison avec la stratégie de la règle de vote.

# **Chapitre II : analyse de signal vocal pour la diagnostique**

## II.1 Introduction

Le signal vocal contient une richesse d'informations telles que : l'identité de la personne, son état émotionnel, son genre, son âge, le contenu lexical, l'état pathologique de la voix, etc. Plus particulièrement, l'état pathologique de la voix dépend des symptômes de certaines maladies (grippe, covid-19,...) [11].

La maladie Covid-19 a touché plus de 600 millions de cas confirmés dans le monde. Ainsi, plusieurs travaux de recherche ont été entamés sur le diagnostic de cette maladie. La conception d'un système de diagnostic exige une étape importante permettant l'extraction des paramètres pertinents en appliquant des outils de traitement du signal vocal. Les paramètres couramment utilisés dans le traitement automatique du signal vocal sont les coefficients MFCC, PLP et les coefficients LPCC.

Dans ce chapitre, on décrira les différentes étapes de l'extraction des coefficients MFCC ainsi que des coefficients LPCC à partir du signal vocal.

## II.2 Définition du signal de parole

Le signal de parole est un signal non stationnaire, redondant. Sa structure est complexe et évolue dans le temps :

- Parfois périodique (semi-périodique) des sons vocaux
- Parfois, c'est aléatoire aux sons non soufflés.

La parole est une succession de séquences sonores et de silences, et le seul moyen qui permet de communiquer la pensée par un système de sons articulés. Les humains sont les seuls êtres vivants qui utilisent un tel type des systèmes structurés, et il est le résultat d'une variation de la pression produite par l'émission d'un son par un locuteur [13].

## II.3 Paramètres du signal de parole

Le signal vocal se caractérise généralement par des paramètres prosodiques utilisés dans plusieurs domaines de traitement du signal vocal tels que l'identification du locuteur, la reconnaissance de la parole, la reconnaissance des émotions. Ces paramètres prosodiques sont :

- La fréquence fondamentale (vibration des cordes vocales).

- L'intensité de la voix (ou énergie).
- La durée successive des segments syllabiques.

## II.4 Traitement de la parole

Le traitement de la parole est une discipline scientifique qui se situe entre le traitement numérique du signal et linguistique où elle connaît depuis longtemps une expansion remarquable et connexe de développement des communications et des technologies [14].

Les différentes fonctions du traitement du signal parole sont illustrées dans la figure (II-1). Ces fonctions sont l'analyse, la synthèse, la reconnaissance de la parole, la reconnaissance du locuteur, la reconnaissance des émotions et reconnaissance de la langue [14]

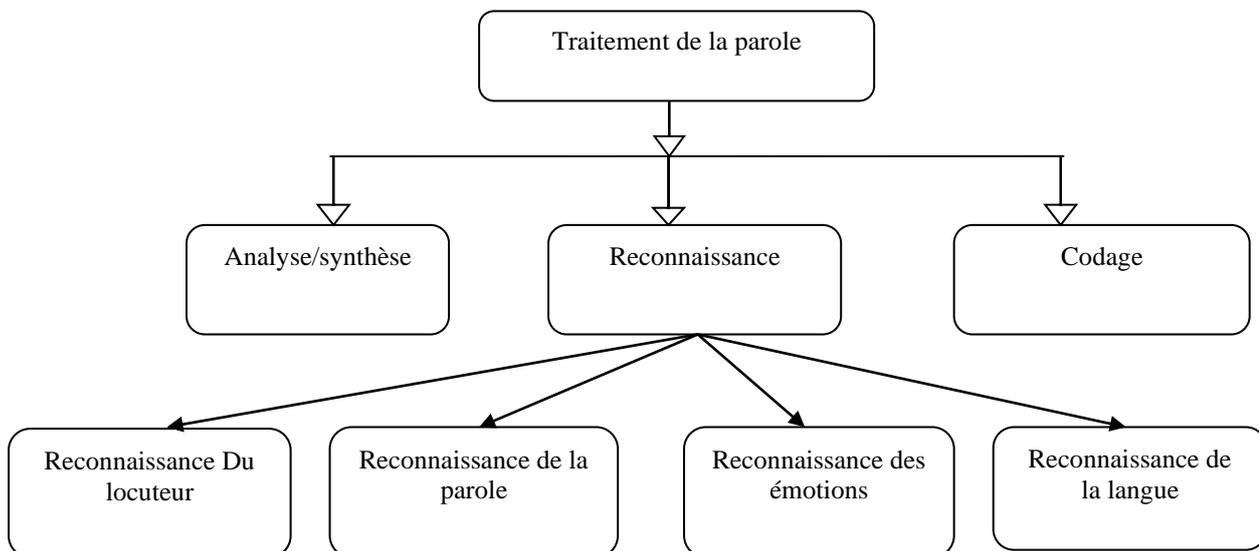


Figure II-1 : Fonctions du traitement de la parole[38]

## II.5 Extraction de paramètres

L'extraction de paramètres (caractéristiques, attributs) est utilisée pour convertir le signal acoustique en une séquence de vecteurs de caractéristiques acoustiques qui portent une bonne représentation du signal vocal d'entrée. Ces caractéristiques sont ensuite utilisées dans l'étape de classification pour prédire la classe du signal parmi des classes considérées dans le système de classification. Généralement des paramètres dynamiques appelés delta et delta delta peuvent être ajoutés pour améliorer les performances du système considéré [15].

## II.5.1 Coefficients cepstraux sur l'échelle Mel (MFCC)

Les coefficients cepstraux en échelle Mel (MFCC, Mel-Frequency Cepstral coefficients) ont été intensivement utilisés comme vecteur de paramètres acoustiques dans les systèmes de reconnaissance de la parole et du locuteur. L'extraction des coefficients MFCC est motivée par les deux propriétés suivantes:

- Déconvolution : Les MFCC séparent les caractéristiques des voies vocales des caractéristiques excitatrices.
- Décorrélation : La transformée en cosinus discrète possède un effet de décorrélation entre les éléments du vecteur de paramètres. Les MFCC sont obtenus par la transformée cosinus inverse du logarithme du spectre de l'énergie du segment de la parole [16].

### II.5.1.1 Étapes de calcul du vecteur de paramètres MFCC

La figure II-2 montre les étapes nécessaires pour obtenir les coefficients MFCC.

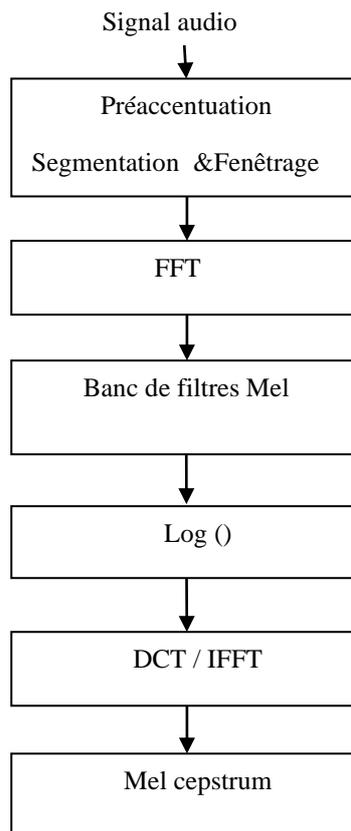


Figure II-2 : Étapes de calcul d'un vecteur de paramètres MFCC

### II.5.1.1.1 Segmentation en trames

Le signal acoustique continu est segmenté en fenêtres de N échantillons, avec un pas de décalage de M échantillons ( $M < N$ ). Comme prétraitement, il est nécessaire de procéder à la préaccentuation du signal en appliquant l'équation de différence du premier ordre aux échantillons  $x(n)$ , avec l'équation suivante [17] :

$$x_a = x(n) - an(n - 1). 0 \leq n \leq N - 1 \quad (\text{II.1})$$

Où a représente le coefficient de préaccentuation qui peut prendre une valeur dans l'intervalle  $0 < a < 1$ .

### II.5.1.1.2 Fenêtrage de Hamming

Considérons  $w(n)$  comme fenêtre où  $0 < n < N - 1$  et N représente le nombre d'échantillons dans chacune des trames, alors le résultat du fenêtrage est le signal  $x_w$  donné par la formule

$$x_w = x_a(n)w(n), 0 \leq n \leq N - 1 \quad (\text{II.2})$$

La fenêtre couramment utilisée est la fenêtre de Hamming dont la fonction est donnée [17] par la formule :

$$W(n) = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right). 0 \leq n \leq N - 1 \quad (\text{II.3})$$

### II.5.1.1.3 Calcul de la transformée de Fourier rapide (Fast Fourier Transforme FFT)

Dans cette étape chacune des trames, de N valeurs, est convertie du domaine temporel au domaine fréquentiel. La FFT est un algorithme rapide pour le calcul de la transformée de Fourier discret (DFT) et est définie par la formule (II.4). Les valeurs obtenues sont appelées le spectre.

$$x(k) = \sum_{n=0}^{N-1} x_w(n) e^{\frac{-2j\pi}{N}kn} \quad 0 \leq k \leq N - 1 \quad (\text{II.4})$$

En général, les valeurs  $x(k)$  sont des nombres complexes et nous nous considérons que leurs valeurs absolues (énergie de la fréquence).

### II.5.1.1.4 Filtrage sur l'échelle Mel

Le spectre d'amplitude est pondéré par un banc de filtres triangulaires espacés M espacés selon une échelle de pente. La correspondance est à peu près linéaire aux fréquences inférieures à 1 kHz et logarithmique aux fréquences supérieures à 1 kHz. Cette relation est donnée par la formule (II.5)

$$m=2595 \log_{10} \left( 1 + \frac{f}{700} \right) \quad (\text{II.5})$$

Le logarithme de l'énergie de chaque filtre est calculé selon l'équation :

$$s(m) = \log(\sum_{k=0}^{N-1} |X_w(k)|^2) \quad 0 < m \leq M \quad (\text{II.6})$$

### II.5.1.1.5 Calcul du cepstre sur l'échelle Mel

Le cepstre sur l'échelle de fréquence Mel est obtenu par le calcul de la transformée en cosinus discrète du logarithme de la sortie des M filtres (reconversion du log-Mel-spectre vers le domaine temporel)

$$C[n] = \sum S[m] \cos(\pi n(m - 1/2)/M) \quad 0 \leq n < M \quad (\text{II.7})$$

$C_0$  est le premier paramètre de la puissance moyenne dans la trame de parole

### II.5.1.1.6 Calcul des paramètres dynamiques des MFCC

La dynamique du signal parole joue un rôle important dans la perception humaine et c'est à travers les dérivées des coefficients ( $A_c$ , coefficients delta ( $\Delta$ ) ou vélocité) et les dérivées secondes ( $A_{Ac}$ , coefficients delta du second ordre ( $\Delta\Delta$ ) ou accélération) des paramètres MFCC statiques ( $C_k$ ) que nous pouvons mesurer cette dynamique.

Les paramètres dynamiques delta des Coefficients statiques  $C_k$  sont définis comme suit[16] :

$$\Delta C_k(t) = \frac{\sum_{i=1}^{i=T} i(C_k(t+i) - C_k(t-i))}{2 \cdot \sum_{i=1}^{i=T} i^2} \quad (\text{II.8})$$

## II.5.2 Codes à prediction linéaire ( Linear Predictive Codes:LPC)

Il est souhaitable de compresser le signal pour la transmission et stockage. Le signal numérique est compressé avant la transmission pour une utilisation efficace des canaux sur les médias sans fil. Pour codeur moyen ou bas débit, le **LPC** est le plus largement utilisé. Le **LPC** calcule un spectre de puissance du signal. Il est utilisé également pour l'estimation formants [18]. **LPC** est l'une des techniques puissantes de l'analyse du signal vocal. Cette technique se base sur la prédiction d'un échantillon à partir des p échantillons passés :

$$\hat{x}(n) = \sum_{i=1}^p a_i x(n - i) \quad (\text{II.9})$$

### II.5.3 coefficients cepstraux de prédiction linéaire Liner prédiction castral coefficients (LPCC)

Les coefficients cepstraux de prédiction linéaire (LPCC) sont des coefficients cepstraux dérivés de l'enveloppe spectrale calculée par LPC.

Il a été observé par Rosenberg et Sambre que les coefficients prédictifs adjacents sont fortement corrélés et que, par conséquent, les représentations avec des caractéristiques moins corrélées seraient plus efficaces, LPCC en est un exemple typique. La relation entre LPC et LPCC a été dérivée à l'origine par Atal en 1974[19].

Dans le traitement de la parole, LPCC analogue à LPC, sont calculés à partir de points d'échantillonnage d'une forme d'onde de parole. Le processus de calcul de LPCC à partir de LPC est illustré sur la figure II-3.

$$c_m = a_m + \sum_{k=1}^{m-1} \left[ \frac{k}{m} \right] c_k a_{m-k} \quad (\text{II -10})$$

Où  $a_m$  est le coefficient de prédiction linéaire,  $c_m$  est le coefficient cepstral.

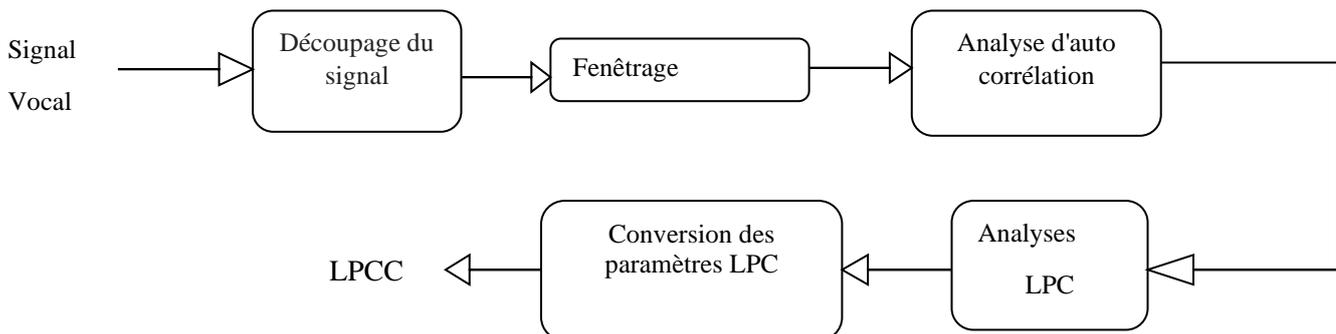


Figure II-3 : Schéma fonctionnel du processus de calcul de LPCC.

Les LPCC ont une faible vulnérabilité au bruit. Les paramètres LPCC génèrent un taux d'erreur inférieur à celui des fonctionnalités LPC. Les coefficients cepstraux d'ordre supérieur sont mathématiquement limités, ce qui entraîne un éventail extrêmement étendu de variances lors du passage des coefficients cepstraux d'ordre inférieur aux coefficients cepstraux d'ordre supérieur. De même, les estimations LPCC sont connues pour avoir une grande sensibilité au bruit de quantification. L'analyse cepstrale sur un signal de parole aigu donne une faible séparabilité source-filtre dans le domaine de la fréquence. Les coefficients cepstraux d'ordre inférieur sont sensibles à la pente spectrale, tandis que les coefficients cepstraux d'ordre supérieur sont sensibles au bruit [20]

## II.6 Etat de l'art sur l'analyse du signal vocal appliquée au diagnostic de la maladie covid-19

Le tableau II-1 présente un état de l'art sur les différentes travaux de recherches appliquées sur le diagnostic de la maladie covid-19 (type de paramètres utilisé, la base de données utilisée et les résultats obtenus).

**Tableaux II-1** Etat de l'art sur l'analyse du signal vocal appliquée au diagnostic de covid-19 [21]

Ref	Caractéristique	Base de données	Résultat
[22]	Fréquence Mel cepstral coefficients (MFCCs)	Données audio de 7 maladies pulmonaires obstructives chroniques (MPOC) patients pendant 90 jours	Aire sous la courbe (AUC) d'environ 0,916 avec XGBoost.
[23]	Forme de transformée de Fourier à court terme (STFT), MFCC, Banque de filtres Mel (MFB) en utilisant le réseau neuronal profond (DNN), réseau neutre convolutif (CNN) et Mémoire à long terme (LSTM)	ensemble audio de Google extraits de 1,8 million de vidéos You tube et la base de données audio Freesound	MFB suivi de STFT donne les meilleures performances sur DNN, CNN et LSTM
[24]	Moments Hu et k-Nearest Classificateur voisin (k-NN)	Signaux audio open source utilisés & ensembles de données de sons et créés deux à l'aide d'expériences de collecte de données : a) Toux sonores dans des environnements et b) 13 patients enregistrements audio, y compris la toux, parole et respiration forcée	Sensibilité de 88,51 % et spécificité de 99,7 % dans une variété de bruits
[25]	MFCC avec Random Forest Classificateur (RFC).	Toux et ronflements forcés de 26 sujets sains superposés avec le bruit AC	Une précision moyenne de $0,96 \pm 0,08$ , un score F1 de $0,96 \pm 0,08$ , et les caractéristiques de fonctionnement du récepteur AUC (ROC) de $0,98 \pm 0,04$ dans la classification des sons de ronflement et de toux
[26]	Analyse visuelle à l'aide de CNN et analyse séquentielle à l'aide du travail de réseau neuronal récurrent (RNN)	Les signaux audio capturés à l'aide d'un capteur piézo de 14 sujets sains comprenant toux, parole, et autres sons	Spécificité CNN : 92,2 % et sensibilité RNN : 87,7 %.
[27]	MFCC avec modèle de mélange gaussien (GMM)	Son respiratoire de 9 asthmatiques et 9 adultes non asthmatiques	Sensibilité de 0,881 et spécificité de 0,995.

[28]	Cepstrogramme et SVM avec fonction de base radiale	Enregistrements de la parole de 16 participants d'âge	Score F1 de 89 % et RMSE de 4,5 respirations/min pour le reta de respiration vocale
[29]	Spectrogramme avec un CNN et un RNN	20 discours de sujets sains enregistré à l'aide d'un microphone et signal respiratoire à l'aide de deux ceintures transducteurs respiratoires	Sensibilité de 91,2 % pour la détection des événements respiratoires et erreur absolue moyenne de 1,01 respiration par minute pour l'estimation de la fréquence respiratoire (détection du signal respiratoire pour la conversation)
[30]	Détection respiratoire : MFCC avec monocouche NN, classification OSA : MFCC, énergie, hauteur, kurtosis et ZCR avec SVM.	90 Discours de sujets masculins et mesures de la qualité du sommeil à l'aide de WatchPAT[31]	Coefficient kappa de Cohen de 0,5 pour la détection de la respiration et 0,54 pour la détection OSA
[32]	Fréquences et bande passante des formants (F1, F2 et F3), HNR, gigue, flux spectral, F0, MFCC et Linéaire coefficients cepstraux de prédiction avec un ensemble de SVM, d'analyse discriminante linéaire et de k-NN	Discours de 25 sujets OSA et 20	Taux de vrais positifs de 88 % et taux de vrais négatifs de 80 % vérifié sur un ensemble de données dans la nature acquis à partir de YouTube.
[33]	L'analyse à composante principale (ACP) sur audio spectrogrammes, les coefficients de la transformée du Fourier rapide(FFT),	Toux agi de 17 patients avoir une toux due à des rhume (n=8), asthme (n=3), allergies (n=1) et toux chronique (n=5)	Taux de vrais positifs : 92 %, taux de faux positifs : 0,5 %.

## II.7 conclusion

Dans ce chapitre, nous avons donné un bref aperçu du signal parole et ses propriétés. Plus précisément, nous avons décrit les différentes étapes d'extraction des paramètres MFCC. De plus, nous avons brièvement discuté des types de paramètres LPC et LPCC. De plus, nous avons donné un état de l'art sur les différents paramètres utilisés dans la tâche de diagnostic de la maladie Covid-19.

# **Chapitre III : Implémentation du système de diagnostic de la maladie COVID-19**

## III.1 INTRODUCTION

Le diagnostic de la maladie COVID-19 est une tâche de grande importance dans le domaine du biomédical permettant d'identifier les personnes infectées par le coronavirus. Les modalités couramment utilisées pour cette tâche sont l'image radiologique (image de rayon x, image CT-scan,...), PCR. Une modalité moins contraignante et moins contagieuse de virus est le signal vocal.

Dans notre travail, on s'intéresse à concevoir et implémenter un système de diagnostic de la maladie Covid-19 en se basant sur l'analyse acoustique du signal vocal combinée avec le classificateur KNN et la stratégie de la règle de vote. Plus particulièrement, notre système consiste à appliquer le classificateur KNN et la règle de vote sur chaque séquence de vecteurs de paramètres représentant un signal vocal d'entrée, pour identifier sa classe parmi trois classes notées par C (COVID), H (Healthy) et S (Symptômes). Notre objectif principal est de chercher la bonne configuration du système de diagnostic permettant d'offrir de meilleures performances.

La conception d'un tel système exige une phase d'apprentissage permettant l'enregistrement des vecteurs de références et leurs classes, ainsi qu'une phase de test permettant de classer les différents signaux et d'évaluer les performances du système de diagnostic. Chacune des phases exige une étape de préparation de données et également une étape d'extraction de paramètres acoustiques tels que les coefficients MFCC, LPCC, PLP, etc. Cette dernière étape a pour objectif de convertir chaque signal d'entrée en une séquence de vecteurs de paramètres en utilisant une méthode d'analyse acoustique du signal vocal.

Dans notre travail, on s'intéresse à appliquer les méthodes d'extraction des paramètres MFCC et LPCC vue de leur pertinence pour différentes tâches de reconnaissance de formes basées sur l'analyse du signal vocal.

Plus particulièrement, le type de paramètres MFCC est utilisé dans plusieurs systèmes de diagnostic de la maladie Covid-19. Ces paramètres sont extraits couramment à partir de chaque fenêtre d'analyse sous forme d'un vecteur de paramètres constitué d'un ensemble de 39 paramètres. On accepte que ces paramètres peuvent être regroupés en deux descripteurs principaux appelés respectivement MFCC et le logarithme d'énergie E. Le premier descripteur est constitué de 12 coefficients MFCC statiques et leurs paramètres dynamiques  $\Delta$  (noté par D) et  $\Delta\Delta$  (noté par A). Le deuxième descripteur est constitué du logarithme de l'énergie (noté par E) et ses paramètres dynamiques  $\Delta$  et  $\Delta\Delta$ . De la même manière de

regroupement les paramètres MFCC, les paramètres LPCC peuvent être également regroupés en descripteur LPCC et descripteur du logarithme d'énergie.

Dans le présent travail, une étude comparative sera menée entre les performances du système de diagnostic basé sur les paramètres MFCC avec celles du système basé sur les paramètres LPCC. L'évaluation du système s'effectue en termes du taux de classification sous une base de données composée de 600 signaux, extraite d'une base de données publique. Ces signaux sont échantillonnés préalablement à 48 KHz, puis sous-échantillonnés à 16 KHz. Cette base de données est initialement divisée en une base d'apprentissage constituée de 300 signaux et une base de test constituée également de 300 signaux.

Différentes questions peuvent se poser pour chercher la bonne configuration du système à implémenter:

- 1- Quelle est la meilleure configuration du classificateur KNN?
- 2- Quel est le meilleur descripteur de paramètres acoustiques?
- 3- Est-ce que l'ajout des paramètres dynamiques améliore les performances du système ?
- 4- Quel est l'effet de l'opération de sous-échantillonnage du signal vocal sur les performances du système ?
- 5- Quel est le meilleur nombre de paramètres permettant d'obtenir de meilleures performances ?

Plusieurs expériences sont effectuées pour répondre sur ces questions. Les différentes étapes de fonctionnement du système sont implémentées sous l'environnement de programmation Matlab avec l'utilisation de la boîte à outils HTK exploitée à l'étape de l'analyse acoustique. Dans la section suivante, on décrira l'étape de la préparation de la base de données et sa répartition.

### **III.2 Etape de préparation de la base de données**

Chaque système de reconnaissance de formes est évalué généralement sous une base de données pour mesurer ses performances. Dans notre système de diagnostic de la maladie Covid-19, nous avons choisi une base de données publique[34], contenant des signaux vocaux dont chacun correspond à une classe parmi les trois classes notées précédemment par C, H et S. Ces signaux échantillonnés à une fréquence de 48 KHz sous le format 'webm' ou 'json', contiennent des segments de la parole, la toux, le bruit, le silence.

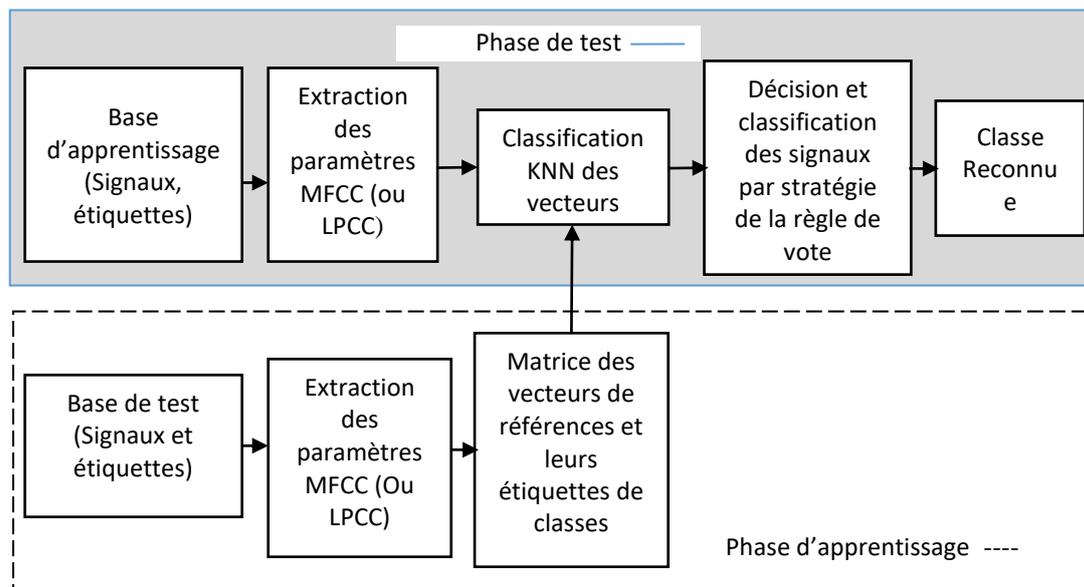
Dans notre travail, nous avons extrait 600 signaux de courte durée à partir des signaux obtenus après l'opération de conversion des signaux du format 'webm' au format 'wav'. Cette

extraction est effectuée en utilisant le logiciel ‘PRAAT’[35]. Les signaux de la classe H contiennent que des segments de parole, alors que les signaux des classes C et S contiennent que des segments de la toux. L’ensemble des 600 signaux est réparti en une base d’apprentissage contenant 100 signaux pour chaque classe, et une base de teste contenant également 100 signaux pour chaque classe.

### III.3 DESCRIPTION DES ETAPES D’IMPLEMENTATION DU SYSTEME PROPOSE

Cette section a pour objectif de décrire les différentes phases et étapes de conception et d’implémentation du système de diagnostic de la maladie COVID-19.

Le schéma synoptique du système proposé basé sur le classificateur KNN est illustré sur la figure (III.1).



**Figure III-1 :** Etapes de conception du système de diagnostic de la maladie Covid-19, basé sur le classificateur KNN et la règle de vote

La conception du système se déroule en une phase d’apprentissage et une phase de test. Ces deux phases utilisent le même processus d’extraction de paramètres (MFCC ou LPCC). L’implémentation de ses phases sera décrite dans les deux sections suivantes.

#### III.3.1 Phase d’apprentissage

La phase d’apprentissage a pour objectif d’enregistrer des vecteurs de références représentant les trois classes considérées (C, H et S), dans le but de les utiliser dans l’étape de classification KNN. Cette phase se déroule en une étape de conversion de chaque signal vocal

d'apprentissage en une séquence de vecteurs de paramètres acoustique et une étape d'enregistrement de l'ensemble des séquences de vecteurs en une matrice. Plus particulièrement, l'étape d'enregistrement consiste premièrement à concaténer l'ensemble des séquences de vecteurs en une matrice dont chaque ligne est un vecteur de paramètres, ensuite enregistrer l'ensemble des indices de classes de ces vecteurs dans un tableau. Dans la section suivante, on décrira l'implémentation de l'étape d'extraction de paramètres MFCC.

### III.3.1.1 Extraction des paramètres MFCC

L'étape d'extraction de paramètres est une étape utilisée dans la phase d'apprentissage et la phase de test. Elle consiste premièrement à segmenter chaque signal vocal en une séquence de fenêtres d'analyse de 30 ms, décalées de 10 ms, puis une analyse cepstrale selon l'échelle Mel sera appliquée sur chaque fenêtre pour extraire un vecteur de 39 coefficients. Ainsi, chaque signal sera converti en séquence de vecteurs de 39 paramètres MFCC. Chaque vecteur est constitué de 12 coefficients statistiques MFCC, d'un paramètre du logarithme d'énergie, ainsi que leurs paramètres dynamiques  $\Delta$  (D) et  $\Delta\Delta$  (A).

L'étape d'extraction est implémentée en utilisant l'outil HCopy de librairie HTK [36]. Cet outil est appliqué comme suit :

**HCopy -C config.txt file\_son.wav file\_param.mfc**

Où :

- **config.txt** : est un fichier de configuration de format texte, contenant les paramètres de configuration de l'étape d'extraction des paramètres acoustiques MFCC. Le tableau III-1 illustre le contenu du fichier de configuration de cette étape.
- **file\_son.wav** : est un fichier son de format **wav** qui représente le signal vocal d'entrée.
- **file\_param.mfc** : est un fichier de sortie écrit en format HTK, contenant la séquence des vecteurs de paramètres MFCC.

**Tableau III .1:** Fichier de configuration (config.txt) de l'étape d'extraction des paramètres MFCC

```
SORCFORMAT=WAV
SOURCEKIND=WAVEFORM
TARGETKIND= MFCC_E_D_A
SOURCERATE=625
SAVECOMPRESSED=f
SAVEWITHCRC=f
WINDOWSIZE=300000.0
TARGETRATE=100000.0
NORMALISE=F
NUMCEPS=12
USEHAMMING=T
PREEMCOEF=0.97
NUMCHANS=26
CEPLIFTER=22
```

Avec :

- **WINDOWSIZE**: représente la durée de la fenêtre d'analyse (exemple:30ms) mesurée en unité de HTK égale à  $10^{-7}$ .
- **TARGETRATE**: représente la durée de décalage entre deux fenêtres d'analyse (exemple: 10 ms).
- **TARGETKIND**: représente les types de paramètres à utiliser. MFCC\_E\_D\_A signifie que le vecteur de paramètres est composé des coefficients MFCC statiques, l'énergie (E) ainsi que leurs paramètres dynamiques  $\Delta$  (D) et  $\Delta\Delta$  (A).
- **NUMCEPS**: est le nombre de coefficients MFCC statiques.
- **USEHAMMING**: représente le choix du fenêtrage par la fonction de Hamming.
- **PREEMCOEF**: est le coefficient de préaccentuation des hautes fréquences.
- **NUMCHANS**: est le nombre de canaux du banc de filtres.
- **CEPLIFTER**: est la longueur du liftering cepstral.
- **SOURCERATE**: est la période d'échantillonnage.

### III.3.1.2 Extraction des paramètres LPCC

Dans cette méthode d'extraction, chaque fenêtre d'analyse du signal sera convertie en un vecteur de 39 paramètres LPCC en appliquant l'analyse cepstrale basée sur l'utilisation des coefficients de prédiction linéaire. Chaque vecteur est constitué de 12 coefficients statistiques LPCC, d'un paramètre du logarithme d'énergie (E), ainsi que leurs paramètres dynamiques  $\Delta$  (D) et  $\Delta\Delta$  (A).

L'étape d'extraction des paramètres LPCC est implémentée en utilisant l'outil HCopy de la bibliothèque HTK [ ]. Cet outil s'applique de la même manière de l'étape d'extraction des paramètres MFCC avec l'utilisation du fichier **config.txt** illustré sur le tableau III.2.

**Tableau III .2:** Fichier de configuration (config.txt) de l'étape d'extraction des paramètres LPCC

```
SOURCEFORMAT = WAV
SOURCEKIND = WAVEFORM
HNET:TRACE    = 1
TARGETKIND = LPCEPSTRA_E_D_A
SOURCERATE= 625
# Unit = 0.1 micro-second :
SAVECOMPRESSED    = F
SAVEWITHCRC      = F
WINDOWSIZE = 300000.0
TARGETRATE = 100000.0
NORMALISE = F
NUMCEPS = 12
USEHAMMING = T
PREEMCOEF = 0.97
LPCORDER  = 12
CEPLIFTER = 22
```

Où :

**LPCEPSTRA\_E\_D\_A** : signifie que le vecteur de paramètres à extraire est composé des coefficients LPCC statiques, de l'énergie (E) ainsi que de leurs paramètres dynamiques  $\Delta$  (D) et  $\Delta\Delta$  (A).

**LPCORDER** : est l'ordre de prédiction linéaire utilisé dans le calcul des coefficients de prédiction linéaire LPC qui seront exploités dans le calcul des coefficients LPCC.

### III.3.2 PHASE DE TEST

La phase de test consiste à classifier chaque signal d'entrée de test et d'évaluer les performances du système de diagnostic en termes du taux de classification des signaux de test.

La classification d'un signal d'entrée se déroule en étape d'extraction de paramètres et une étape de classification de la séquence de vecteurs obtenue en utilisant le classificateur KNN combiné avec la stratégie de la règle de vote. L'extraction de paramètres s'effectue de la même manière utilisée dans la phase d'apprentissage. Le classificateur KNN classifie chaque vecteur de la séquence, puis la stratégie de la règle de vote est appliquée sur la séquence d'indices de classes obtenue pour décider sur la classe du signal d'entrée.

Les performances du système de diagnostic sont évaluées en tenant compte le taux de classification des vecteurs (TCV) et le taux de classification des signaux TCS de la base de données de test. Ces taux sont définis comme suit:

$$TCV = \frac{N_{V_C}}{N_{V_T}} \cdot 100 \quad (III.1)$$

Où  $N_{V_T}$  représente le nombre des vecteurs de paramètres de tous les signaux de la base de test,  $N_{V_C}$  représente le nombre de vecteurs de paramètres correctement classifiés.

$$TCS = \frac{N_{S_C}}{N_{S_T}} \cdot 100 \quad (III.2)$$

Où  $N_{S_T}$  représente le nombre des signaux de la base de test,  $N_{S_C}$  représente le nombre de signaux correctement classifiés.

## III.4. Expériences et résultats

Dans cette section, nous présentons les différentes expériences menées pour chercher la bonne configuration de notre système de diagnostic, à savoir : la bonne configuration de classificateur KNN (la valeur optimale de k vecteurs plus proche voisin, la distance optimale) au sens du taux de classification, le meilleur descripteur de paramètres acoustiques, ainsi que

le meilleur nombre de paramètres permettant d'obtenir de meilleures performances. De plus, nous étudions l'influence de la fréquence d'échantillonnage sur les performances du système.

### **III.4.1 Paramètres optimaux du classificateur KNN**

Le fonctionnement du classificateurs KNN dépend de plusieurs paramètres de configuration tels que: le nombre des vecteurs les plus proches voisins  $k$  et la distance entre un vecteur de paramètres de test et un vecteur de paramètres d'apprentissage. Ainsi, le premier objectif de notre étude est de choisir le meilleur nombre  $k$  et la meilleure distance pour chaque type de paramètres (MFCC ou LPCC). Les expériences de cette étude s'effectuent en fixant à chaque fois une distance et en variant  $k$  de 1 à 50.

#### **III.4.1.1 Paramètres optimaux du classificateur KNN combiné avec la méthode d'extraction des paramètres MFCC**

L'objectif de cette expérience consiste à choisir les paramètres optimaux du système de diagnostic basé sur le classificateur KNN combiné avec la règle de vote et la méthode d'extraction des paramètres MFCC.

La figure III-2 présente l'évolution du taux de classification TCS en fonction de la valeur de  $k$ , chaque courbe correspond à une distance (Euclidienne, Cityblock, Cosinus ou corrélation). Cette présentation nous permet d'évaluer globalement les performances du système de diagnostic. Nous pouvons observer que la valeur optimale  $k_p$  correspondant à la valeur maximale du TCS est inférieure à 15 quelque soit la distance considérée. Les 15 premières valeurs de TCS correspondant à chaque type de distance sont illustrées sur le tableau III. 3. Le tableau III.4 présente le taux de classification maximal et le  $k$  optimal correspondant à chaque distance.

Les points les plus importants remarqués à partir de ces résultats sont donnés comme suit :

- Toutes les distances donnent un taux TCS proche de 60% en choisissant  $k$  égal à 1.
- Le meilleur taux de classification TCS de 63.67% est obtenu en choisissant la distance 'correlation' avec  $k_p$  égal à 8.
- Le TCS présente de grande étendue de variation dans le cas des distances : Cityblock, Correlation et Cosine. De plus, ces distances présentent une décroissance de TCS au fur et à mesure que  $k$  augmente. Cela justifie l'influence de  $k$  sur les performances pour ces distances.

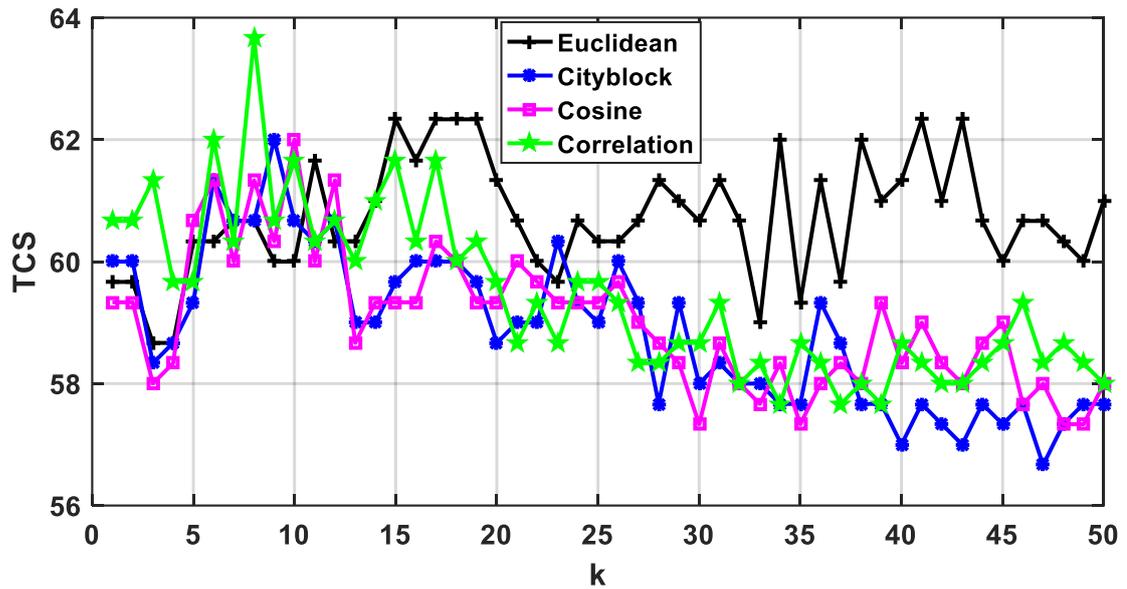


Figure III.2 : Evolution du TCS en fonction de la valeur de k pour les différentes distances, en utilisant les paramètres MFCC

Tableau III.3 : Taux de classification TCS pour les quinze premières valeurs de k correspondant à chaque distance, en utilisant les paramètres MFCC.

Distance \ K	Cityblock	Euclidean	Cosine	Correlation
1	60.00	59.67	59.33	60.67
2	60.00	59.67	59.33	60.67
3	58.33	58.67	58.00	61.33
4	58.67	58.67	58.33	59.67
5	59.33	60.33	60.67	59.67
6	61.33	60.33	61.33	62.00
7	60.67	60.67	60.00	60.3333
8	60.67	60.67	61.33	63.67
9	62.00	60.00	60.33	60.67
10	60.67	60.00	62.00	61.67
11	60.33	61.67	60.00	60.33
12	60.67	60.33	61.33	60.67
13	59.00	60.33	58.67	60.00
14	59.00	61.00	59.33	61.00
15	59.67	62.33	59.33	61.67

Tableau III-4 : Taux de classification maximal et k optimal correspondant à chaque distance en utilisant les paramètres MFCC.

Distance	Euclidean	Cityblock	Cosine	Correlation
Kp	15	9	10	8
TCS (%)	62.33	62.00	62.00	63.67

### III.4.1.2 Paramètres optimaux du classificateur KNN combiné avec la méthode d'extraction des paramètres LPCC

Cette expérience a pour objectif de choisir les paramètres optimaux du système de diagnostic basé sur le classificateur KNN combiné avec la règle de vote et la méthode d'extraction des paramètres LPCC.

La figure III-3 illustre l'évolution du taux de classification TCS en fonction de la valeur de k. Le tableau III.5 présente les 15 premières valeurs de TCS pour chaque type de distance. La valeur optimale de k et la valeur maximale du TCS pour chaque type de distance sont données dans le tableau III.6.

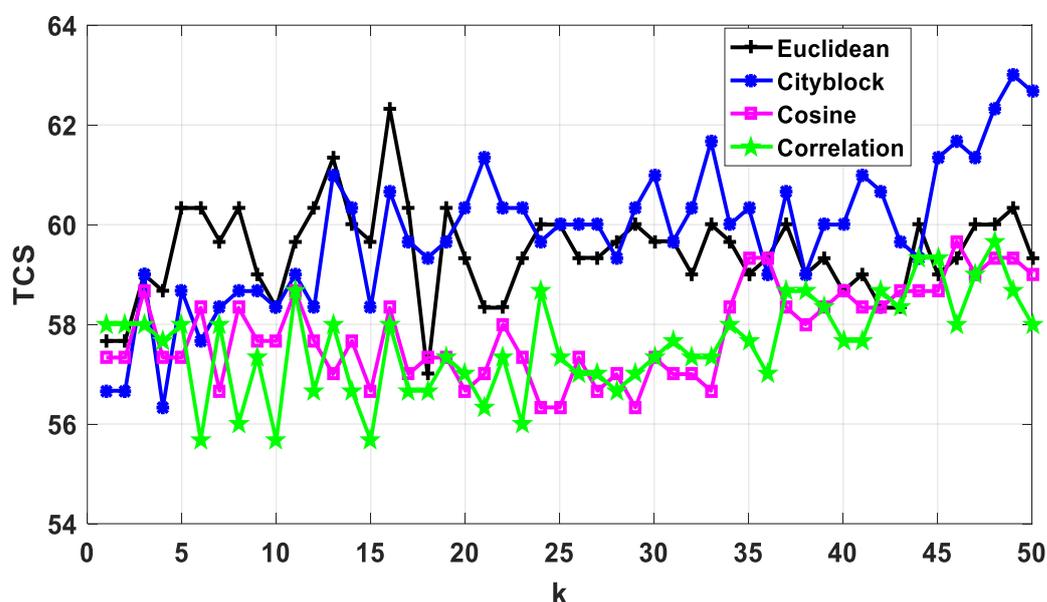


Figure III.3 : Evolution du TCS en fonction de la valeur de k pour les différentes distances, en utilisant les paramètres LPCC

A partir de cette figure et ces tableaux, nous pouvons donner les remarques suivantes:

- Toutes les distances donnent un taux TCS proche de 57% en choisissant k égal à 1.
- Le meilleur taux de classification TCS de 63% est obtenu en choisissant la distance 'Cityblock avec k égal à 49.
- Les distances Euclidean, Cityblock, Cosine et corrélation donnent des taux TCS maximaux égales respectivement aux 62.33%, 63%, 59.66% et 59.66%, qui correspondent aux valeurs de k optimales égales aux 16, 49, 46 et 48. Ces grandes valeurs de k permettent d'augmenter ainsi le temps de classification des vecteurs par rapport des valeurs de k optimales correspondant au système de diagnostic basé sur la méthode d'extraction des paramètres MFCC. Les trois derniers types de distances présentent une croissance du taux

TCS au fur et à mesure que k augmentent. Alors que le premier type de distance présente de petites fluctuations du taux TCS.

**Tableau III.5:** Taux de classification TCS pour les quinze premières valeurs de k correspondant à chaque distance, en utilisant les paramètres LPCC.

Distance K	Cityblock	Euclidean	Cosine	Correlation
1	56.67	57.67	57.33	58.00
2	56.67	57.67	57.33	58.00
3	59.00	59.00	58.67	58.00
4	56.33	58.67	57.33	57.67
5	58.67	60.33	57.33	58.00
6	57.67	60.33	58.33	55.67
7	58.33	59.67	56.67	58.00
8	58.67	60.33	58.33	56.00
9	58.67	59.00	57.67	57.33
10	58.33	58.33	57.67	55.67
11	59.00	59.67	58.67	58.67
12	58.33	60.33	57.67	56.67
13	61.00	61.33	57.00	58.00
14	60.33	60.00	57.67	56.67
15	58.33	59.66	56.67	55.67

**Tableau III.6:** Taux de classification maximal et k optimal correspondant à chaque distance en utilisant les paramètres LPCC.

Distance	Euclidean	Cityblock	Cosine	Correlation
Kp	16	49	46	48
TC (%)	62.33	63	59.66	59.67

Ainsi, le système de diagnostic de la maladie Covid-19 basé sur le classificateur KNN combiné avec la méthode d'extraction des paramètres MFCC donne de meilleures performances que celui basé sur la méthode d'extraction des paramètres LPCC. Dans les sections suivantes, on présentera des expériences qui se basent sur la méthode d'extraction des paramètres MFCC.

### III.4.2 Meilleur descripteur des paramètres MFCC

Cette expérience a pour objectif de chercher les meilleurs descripteurs (MFCC, E et leurs paramètres dynamiques) ainsi que leur meilleure combinaison. Cette expérience s'effectue en utilisant la bonne configuration du classificateur KNN obtenue précédemment (Distance correlation avec kp égal à 8). Dans cette expérience, les performances sont évaluées en

utilisant le taux TCS et le taux de classification des vecteurs TCV.

A partir des résultats du tableau III.7, nous pouvons tirer les points suivants :

- L'application de la stratégie de règle de vote améliore les résultats en termes de taux de classification pour tous types de paramètres MFCC.
- Le descripteur MFCC est meilleur par rapport au descripteur énergétique E.
- L'ajout des paramètres dynamiques (D et A) améliore les performances du système quelque soit le descripteur considéré, mais il augmente la dimensionnalité des vecteurs de paramètres acoustiques.
- L'ajout des paramètres énergétiques (E, D et A) améliore légèrement le taux de classification des signaux TCS.

**Tableau III.7 :** Taux de classification TCV et TCS pour les différents descripteurs : MFCC, E et leurs paramètres dynamiques.

Paramètre	Nombre de paramètres	TCV%	TCS%
MFCC	12	50.51	60.67
E	1	28.36	33.33
MFCC_DA	36	51.40	63
E_DA	3	37.32	42.33
MFCC_E	13	51.54	60.67
MFCC_EDA	39	51.41	63.67

### III.4.3 Effet de la réduction de la dimensionnalité des vecteurs de paramètres MFCC sur les performances du système

La combinaison de paramètres MFCC\_EDA a permis d'obtenir le meilleur taux de classification de signaux TCS égal à 63.67%. Cette combinaison de 39 paramètres est répartie comme suit :

Mfcc1, Mfcc2, ..., Mfcc12, E,  $\Delta$ Mfcc1,  $\Delta$ Mfcc2, ...,  $\Delta$ Mfcc12,  $\Delta$ E,  $\Delta\Delta$ Mfcc1,  $\Delta\Delta$ Mfcc2, ...,  $\Delta\Delta$ Mfcc12,  $\Delta\Delta$ E.

L'objectif de cette expérience est d'étudier l'effet de réduction de la dimension des vecteurs de paramètres sur les performances du système. Plus particulièrement, nous cherchons le nombre de paramètres réduit permettant d'obtenir un bon taux de classification avec un temps d'exécution et espace mémoire faibles.

La figure III.4 présente le taux TCS en fonction du nombre paramètres, en tenant compte la bonne configuration du classificateur KNN présentée dans le tableau III.4.

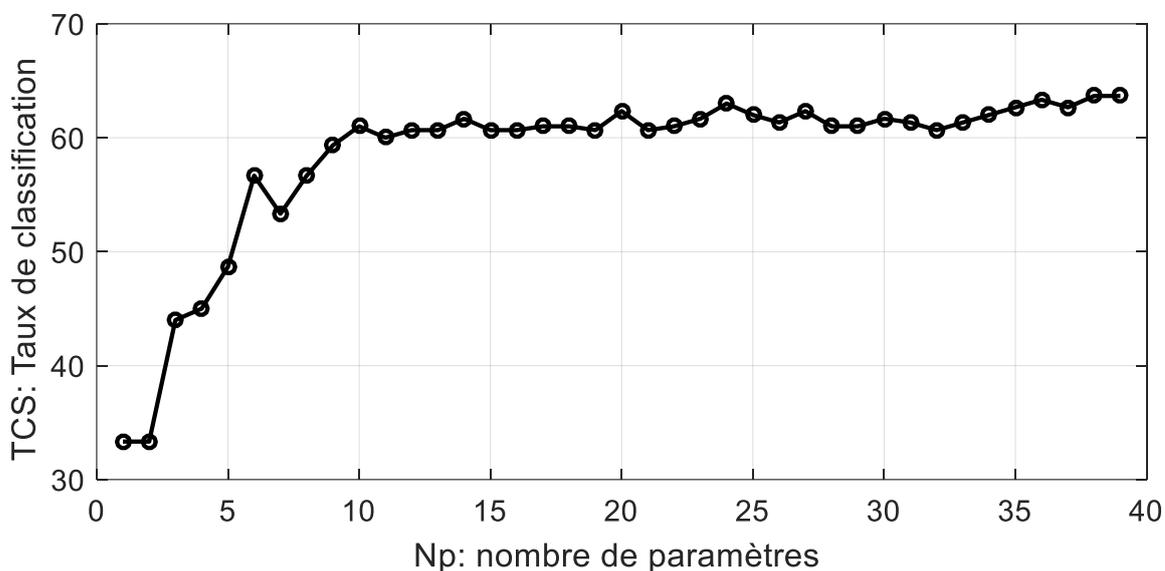


Figure III.4 : Evolution du TCS en fonction du nombre de paramètres MFCC

La figure III.4 montre une croissance de la courbe de TCS qui atteint le début d'un plateau à un nombre  $N_p$  de 10 paramètres avec un taux TCS égal à 61%. Cette valeur de TCS représente approximativement 95% de la valeur finale de TCS (63.67%) correspondant au  $N_p$  de 39 paramètres. Ce résultat montre la pertinence des 10 premiers paramètres pour cette tâche de diagnostic. Cette réduction de nombre de paramètres permet d'obtenir un Taux TCS acceptable avec une réduction de l'espace mémoire et du temps de calcul.

### III.4.3 Effet de la fréquence d'échantillonnage les performances du système

Les signaux audio des bases de données d'apprentissage et de test utilisés dans nos expériences précédentes sont sous-échantillonnés à une fréquence d'échantillonnage  $f_s$  égale à 16 KHz à partir d'une fréquence d'échantillonnage initiale  $F_{sn}$  égale à 48000. Ce sous-échantillonnage a pour but de minimiser le temps de calcul et l'espace mémoire.

Cette expérience a pour objectif d'étudier l'effet de l'opération de sous-échantillonnage sur les performances du système de diagnostic en choisissant des fréquences d'échantillonnage de valeurs entières obtenues en divisant la fréquence d'échantillonnage initiale  $F_{sn}$  par des valeurs entières suivantes : 1, 2, 3, 4, 5, 6, 12.

Le tableau III.8 illustre le taux de classification TCS en fonction de la fréquence d'échantillonnage  $f_s$ .

**Tableau III.8 :** Taux de classification TCS en fonction de la fréquence d'échantillonnage fs.

Fs (Hz)	4000	8000	9600	12000	16000	24000	48000
Fs/Fsn	12	6	5	4	3	2	1
TCS (%)	55.33	56.67	59.67	62	63.67	64.33	65.33

Les résultats nous permettent de remarquer les points suivants :

- Le choix de fs égale à 48000 permet d'obtenir le meilleur taux TCS de 65.33. En revanche, ce choix augmente l'espace mémoire et le temps de calcul.
- Les fréquences fs inférieures à 8000 présentent de faibles taux TCS. Ceci peut être justifié par la limitation de la fréquence maximale des signaux par l'application du sous-échantillonnage.
- Le choix de fs égale à 16000 Hz permet de réduire le nombre d'échantillons à trois fois et d'obtenir un taux TCS acceptable. Ainsi, ce choix réalise un compromis entre la précision et la complexité du système de diagnostic.

### III.5. Conclusion

Dans ce chapitre, nous avons décrit notre système de diagnostic de la maladie Covid-19 basé sur le classificateur KNN combiné avec la règle de vote. Les types de paramètres acoustiques MFCC et LPCC ont été utilisés et étudiés dans l'étape d'extraction de paramètres. Au début du chapitre, plusieurs questions ont été posées sur la conception du système pour chercher sa bonne configuration. Ainsi, plusieurs expériences ont été effectuées pour répondre sur ces questions. Avant d'entamer la partie pratique, les différentes phases et étapes de fonctionnement du système de diagnostic ont été décrites.

La première expérience nous a permis de chercher la bonne configuration du classificateur KNN ainsi que le meilleur type de paramètres. Les résultats nous ont montré que le choix de la distance Correlation et le nombre de vecteurs les plus proche voisins égal à 8 donne de meilleures performances du système en utilisant les paramètres MFCC qui a montré ces avantages par rapport au type de paramètres LPCC de points de vue précision et complexité.

Les résultats de la deuxième expérience nous a montré que la combinaison des paramètres statiques et dynamiques des descripteurs MFCC et E conduit aux meilleures performances.

Dans la troisième expérience, nous avons étudié l'effet de la réduction de la dimensionnalité des vecteurs de paramètres MFCC ainsi que la recherche du meilleur nombre de paramètres permettant d'obtenir de bonnes performances. Les résultats nous ont montré que le choix des premiers paramètres MFCC est suffisant pour donner de bonnes performances.

La quatrième expérience nous permis d'étudier l'effet du sous-échantillonnage des signaux des bases de données d'apprentissage et de test, ainsi que le bon choix de la fréquence d'échantillonnage  $F_s$ . Les résultats ont montré que le choix de la fréquence d'échantillonnage égale à 16000 Hz conduit au bon compromis entre la précision et la complexité du système.

Finalement, les résultats des différentes expériences nous permis de conclure que la bonne configuration du système de diagnostic de la maladie Covid-19 consiste à considérer les points suivants :

- Le classificateur KNN se base sur la distance Correlation avec un nombre de vecteurs les plus proches voisins égal à 8.
- La fréquence d'échantillonnage est égale à 16 KHz.
- La meilleure combinaison de paramètres est celle de MFCC\_EDA.
- L'utilisation des dix premiers paramètres acoustique MFCC conduit à des performances acceptables.

## CONCLUSION GENERALE

Les systèmes de diagnostic automatique de la maladie Covid-19 ont connu une progression scientifique rapide ces deux dernières années. Ces systèmes peuvent être considérés généralement comme des systèmes de reconnaissance de formes qui utilisent des modalités telles que l'image médicale et le signal parole (vocal). Ainsi, la conception de tels systèmes exige une phase d'apprentissage pour modéliser les différentes classes des signaux ou d'images, et une phase de test pour évaluer les performances du système de diagnostic. Chacune des phases exige une étape d'extraction de paramètres. La tâche de diagnostic consiste à reconnaître la classe du signal ou de l'image d'entrée en effectuant une étape d'extraction de paramètres et une étape de classification qui utilise des modèles de classes ou des références obtenues dans la phase d'apprentissage.

Notre travail consiste à concevoir et implémenter un système de diagnostic de la maladie Covi-19 basé sur l'analyse du signal vocal et le classificateur KNN combiné avec la stratégie de la règle de vote. Plus particulière, l'analyse du signal vocal est utilisée dans l'étape d'extraction de paramètres pour convertir chaque signal en une séquence de vecteurs de paramètres MFCC ou LPCC. La classification KNN permet de classier chaque vecteur de paramètres en classe, ensuite la stratégie de la règle de vote est appliquée sur la séquence d'indices de classes obtenues pour reconnaître la classe la plus voté du signal. Les performances de ce système sont évaluées sous une base de données de 600 signaux audio de trois classes (H : normal, C : Covid, S : Symptôme), répartie en une base de données d'apprentissage de 300 signaux et une base de données de test de 300 signaux.

Plusieurs expériences ont été effectuées pour chercher la bonne configuration du système de diagnostic. Les résultats nous ont montré de performances acceptables d'un taux de classification de signaux égal à 63.67 en utilisant le type de paramètres MFCC et en appliquant la classification KNN basée sur la distance « Corrélacion » avec la prise du nombre de vecteurs les plus proches voisins égal à 8.

Finalement, comme perspectives à cette étude, nous proposons de :

- ✓ Utiliser d'autres classificateurs tels que SVM, HMM, ADI, ANN ...etc.
- ✓ Evaluer les performances du système sur une base de données plus large.
- ✓ Utiliser d'autre analyse du signal vocal telle que l'analyse par ondelettes.

## Références bibliographiques

- [1] FATEH GHAZALI, ABDENOUR HACINE-GHARBI, PHILIPPE RAVIER, and TAYEB and MOHAMADI, "Extraction and selection of statistical harmonics features for electrical appliances identification using kNN classifier combined with voting rules method," vol. 27, no. 4, 2019.
- [2] H. Bengacemi, A. Hacine-Gharbi, P. Ravier, K. Abed-Meraim, and O & Buttelli, "Surface EMG Signal Classification for Parkinson's Disease using WCC Descriptor and ANN Classifier," in *the 10th International Conference on Pattern Recognition Applications and Methods (ICPRAM)*, 2021, pp. 287-294.
- [3] Rima Touahria, Abdenour Hacine-Gharbi, and Philippe Ravier, "Discrete Wavelet based Features for PCG Signal Classification using Hidden Markov Models," in *the 10th International Conference on Pattern Recognition Applications and Methods (ICPRAM)*, 2021, pp. 334-340.
- [4] Ouissam Zealouk et al., "Analysis of COVID-19 Resulting Cough Using Formants and Automatic Speech Recognition System," *Journal of Voice*, June 2021.
- [5] Diemer and Arnaud, "Modéliser le COVID-19, défis et perspectives," 2020.
- [6] Coronavirus : définition, transmission et symptômes, 2022.
- [7] AURELIE BALIZE, "c'est quoi un coronavirus: origine, nom, mutation, symptomes.," *le journal des femmes*, 2020.
- [8] Mustafa Ghaderzadeh and Farkhondeh Asadi, "Deep Learning in the Detection and Diagnosis of COVID-19 Using Radiology Modalities: A Systematic Review," *Journal of Healthcare Engineering*, 2021.
- [9] Vladimir Despotovic, Muhannad Ismael, Maël Cornil, and Roderick Mc Call and Guy Fagherazzi, "Detection of COVID-19 from voice, cough and breathing patterns: Dataset and preliminary results," *Comput Biol Med*, Oct 2021.
- [10] Sai Swarupa R Vulasala, Dheeraj R Gopireddy, Priya Bhosale, and and Mayur K Virarkar, "Review of the role of diagnostic modalities and imaging findings in the COVID-19 pandemic," *World J Radiol*, p. 50–54, Feb 2022.
- [11] Mohanad Alkhodari, Ahsan H, and Khandoker, "Detection of COVID-19 in smartphone-based breathing recordings: A pre-screening deep learning tool," *PLOS ONE*, 2022.
- [12] Warda M. Shaban, Asmaa H. Rabie, Ahmed I. Saleh, and M.A. Abo-Elsoud, "A new COVID-19 Patients Detection Strategy (CPDS) based on hybrid feature selection and enhanced KNN classifier," *Knowledge-Based Systems*, 2020.
- [13] Book P. Taylor and R. Caley, "The architecture of the Festival speech synthesis system," Jean 1998.
- [14] H. Bourslard, T. Dutoit, J. Hancq, et H. Leich. R. Boite, *traitement de la Parole*, 2000.
- [15] Veton Z, Këpuska, Hussien A, and Elharati, "Robust Speech Recognition System Using Conventional and Hybrid Features of MFCC, LPCC, PLP, RASTA-PLP and Hidden Markov Model

- Classifier in Noisy Conditions," *Journal of Computer and Communications*, pp. 56677,9, 2015.
- [16] Yazid ATABI, RECONNAISSANCE AUXOMATIQUE DES EMOTIONS A PARTIR DU SIQNAL ACOUSTIQUE, FEVRIER 17, 2008.
- [17] MOHAMADI FAIZA and CHARIF RIMA, reconnaissance acoustique des émontions basé sur les madéles de Marcov cachés HMM.
- [18] Namrata Dave, "Feature Extraction Methods LPC, PLP and MFCC In Speech Recognition," *INTERNATIONAL JOURNAL FOR ADVANCE RESEARCH IN ENGINEERING AND TECHNOLOGY*, 2013.
- [19] Atal B.S., "Towards Detennining Articulator Positions from the Speech Signal," in *Proc. Speech Comm. Seminar*, Stockholm, Sweden, 1974, pp. 1-9.
- [20] Sabur Ajibola Alim and Nahrul Khair Alang Rashid, "Some Commonly Used Speech Feature Extraction Algorithms," 2018.
- [21] b, Björn W. Schullera,c Gauri Deshpandea, Audio, Speech, Language, & Signal Processing fo rCOVID-19: A Comprehensive Overview, nov 29, 2020.
- [22] L. Di Perna et al., "An automated and unobtrusive system for cough detection," , sydeny, australia, 2017.
- [23] B. Timmermans, L. Aroyo E. van Miltenburg, "the VU Sound Corpus: Adding More Fine-grained Annotations to the Freesound Database," in *Title of host publicationProceedings of the Ninth International Conference on Language Resources and Evaluation (LREC 2016)*, 2016.
- [24] Carlos Hoyos-Barceló, Paul Lesso, Pablo Casaseca-de-la-Higuera Jesus Monge-Alvarez, "Robust detection of audio-cough events using local Hu moments," *IEEE Journal of Biomedical and Health Informatics*, 2018.
- [25] S. Vhaduri, Nocturnal Cough and Snore Detection Using Smartphones in Presence of Multiple Background-Noises, 2020.
- [26] K. Odame, J. Amoh, "Deep neural networks for identifying cough sounds," *IEEE transactions on biomedical circuits and systems*, 2016.
- [27] B.-S. Lin B.-S. Lin, "Automatic wheezing detection using speech recog nition technique," *Journal of Medical and Biological Engineering* 36 (4), 2016.
- [28] M. I. Y. Arafath K., A. Routray, "Automatic measurement of speech breathing rate," *IEEE*, 2019.
- [29] H. Strik, V. S. Nallanthighal, Deep sensing of breathing signal during conversational speech.
- [30] E. Dafna, Y. Zigel, R. M. Simply, "Obstructive sleep apnea (osa) classi-fication using analysis of breathing sounds during speech," *IEEE*, 2018.
- [31] L. Lim, Y. K. Chong Y. J. Gan, Validation study of watchpat 200 for diagnosis of osa in an asian cohort, 2017.
- [32] I. Trancoso, A. Abad, T. Paiva, M. C. Botelho, "Speech as a biomarker for obstructive sleep apnea

detection".

- [33] T. Lee, S. Liu, M. Rosenfeld, S. N. Patel E. C. Larson, "Accurate and privacy preserving cough sensing using a low-cost microphone".
- [34] T. Teijeiro, D. Atienza, L. Orlandic, "the coughvid crowdsourcing dataset, a corpus for the study of large-scale cough analysis algorithms," *sci data journal*, 8, 156, 2021.
- [35] P. & Weenink, D. Boersma. (2014) Praat: doing phonetics by computer.
- [36] S. Young, "The HTK book ( HTK version 3.4)," 2006.
- [37] Regaigui Abir and Bensbaa Nour ElHouda, Identification des appareils électriques basée sur le classificateur KNN combiné avec la règle de vote, 2019.
- [38] Yassamine Aziza, Modélisation AR et ARMA de la parole pour une vérification robuste du locuteur dans un milieu bruyant en mode dépendant du texte, 2013.