



وزارة البحث العلمي والتعليم العالي

MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET
DE LA RECHERCHE SCIENTIFIQUE

جامعة عبد الحميد بن باديس مستغانم

Université Abdelhamid Ibn Badis Mostaganem

كلية العلوم والتكنولوجيا

Faculté des Sciences et de la Technologie

DEPARTEMENT DE GENIE ELECTRIQUE



MEMOIRE

Présenté pour obtenir le diplôme de

MASTER EN TELECOMMUNICATIONS

Par

MEHALA Ikram

LARADJI Sabria

Intitulé du sujet

Détection des mouvements humains par classification des signaux micro-Doppler en utilisant la technique LSTM

Devant le jury composé de :

President:	OULDALI Abdelaziz	MCA	Université de Mostaganem
Examineur:	ABED Mansour	Professeur	Université de Mostaganem
Encadrante:	BENCHELLAL Amel	MCB	Université de Mostaganem
Co- Encadreur:	NAHI Ahmed	Doctarant	Université de Mostaganem

Année Universitaire 2025/2026

Remerciements

Nous tenons à exprimer notre profonde gratitude à toutes les personnes qui ont contribué, de près ou de loin, à la réalisation de ce mémoire.

*Nous adressons nos sincères remerciements à nos encadrants, **Madame BENCHELLAL Amel** et **NAHI Ahmed**, pour leur encadrement, leurs conseils précieux, leur disponibilité et leur accompagnement tout au long de ce travail. Leur soutien nous a permis de mener à bien ce projet avec rigueur et persévérance.*

Nous remercions également l'ensemble des enseignants du département, pour la qualité de la formation dispensée tout au long de notre parcours académique, ainsi que pour les connaissances et compétences qu'ils nous ont transmises.

*Nous adressons également nos sincères remerciements aux membres du jury, **Professeur ABED Mansour** et **Monsieur OULDALI Abdelaziz**, pour l'honneur qu'ils nous font en acceptant d'évaluer ce travail. Nous leur sommes reconnaissants pour le temps consacré à l'examen de ce mémoire ainsi que pour leurs remarques, suggestions et observations qui contribueront à l'amélioration de nos travaux futurs.*

*Nous exprimons aussi notre reconnaissance au laboratoire de recherche **LSS** pour nous avoir accueillis et offert un cadre de travail favorable à la recherche et à l'innovation.*

*Nous adressons nos remerciements au responsable du laboratoire, **Professeur ABED Mansour**, pour son soutien, ses orientations et l'intérêt qu'il a porté à notre travail.*

Enfin, nous remercions chaleureusement toutes les personnes qui ont contribué, de près ou de loin, à l'aboutissement de ce mémoire.

Dédicace

*****À moi-même, d'abord*****

À celle qui a emprunté un chemin qui n'a jamais été facile, qui a trébuché à de nombreuses reprises, mais qui a toujours choisi de se relever.

À cette âme qui a porté ses rêves en silence, comme une promesse incassable.

Me voici aujourd'hui.... Certes, je n'ai pas atteint mon rêve, mais je suis allée assez loin pour être fière de moi-même.

À ceux qui me connaissaient avant même que je me connaisse moi-même.

À cette lumière qui éclaire mes jours les plus sombres lorsque les épreuves cherchent à m'éteindre.

À ces mains qui m'ont toujours soutenue, dans chacun de mes instants, dans chacune de mes faiblesses comme de mes victoires.

*****À ma chère mère, Assia, et à mon cher père, Mohamed. *****

À mon tout premier refuge, à ma première source de sécurité, et aux prières les plus sincères.

À ceux qui ont cru en moi, même lorsque je doutais de moi-même.

À ceux qui ont semé en moi la conviction que l'impossible n'est qu'une idée.

***Vous êtes le commencement de tout, la raison de chacun de mes pas, et c'est à vous que revient tout le mérite de ce que je suis devenue. Merci pour votre amour, vos sacrifices et votre confiance inébranlable. ***

*****À mes sœurs, Norhane et Zhor. *****

À ces éclats de rire qui ont su alléger les jours les plus difficiles.

À ce soutien qui ne m'a jamais fait défaut,

Vous avez toujours été une part de ma force, même lorsque je ne trouvais pas les mots.

***Merci d'avoir été présentes, par votre affection, votre soutien et votre bienveillance. Vous occupez une place précieuse dans mon cœur, et chacun de mes succès porte un peu de vous. ***

*****À mon frère, Nacer. *****

À celui dont la présence a toujours été une source de force.

À celui qui m'a soutenue, encouragée et rappelé, souvent sans le savoir, que je n'étais jamais seule.

Merci d'avoir toujours été là, dans les moments de joie comme dans les épreuves.

***Que cette réussite soit aussi la tienne, car ton soutien, ta confiance ont contribué à faire de ce parcours une réalité. Avec toute mon affection et ma gratitude. ***

*****À ma chère binôme, Ikram. *****

À celle qui a partagé avec moi cinq années d'études, de défis, mais aussi de réussites et de précieux souvenirs.

Merci d'avoir été une compagne de route, présente dans les moments les plus exigeants comme dans les plus heureux.

Nos cinq années passées côte à côte resteront gravées dans ma mémoire.

***Merci pour tout ce chemin parcouru ensemble. ***

*****Et enfin... à moi-même, une fois encore. *****

Non pas parce que le voyage est terminé, mais parce que ce qui m'attend est plus vaste et plus beau,

Que cette étape ne soit que le début de tout ce que j'ai toujours rêvé d'accomplir.

Laradji sabria

Dédicaces

Je dédie ce travail à

À ma mère

Je dédie ce travail à ma chère mère ḳhadidja, en témoignage de mon amour et de ma profonde gratitude pour son soutien, ses sacrifices, ses prières et son amour. Elle a été la lumière de mon chemin et mon véritable soutien à chaque étape, et a assumé tous les rôles sans fatigue. Que Dieu la garde.

À mon père

Je dédie ce travail à mon cher père dahou, en témoignage de mon respect et de ma reconnaissance pour son soutien et ses efforts constants.

À mes deux chères sœurs

Manel et Maya, qui ont cru en moi et m'ont encouragée, même par un simple mot.

À mon cher frère Amer

Qui malgré sa maladie a été une source de joie et de sourire pour moi. Que Dieu le garde.

*Je dédie également le fruit de ce travail à tous mes amis, et plus particulièrement à mon amie et sœur et **mon binôme Sabrina**, qui a partagé avec moi les jours difficiles avant les moments de bonheur, ainsi que les instants de fatigue et de réussite depuis le début de mon parcours universitaire.*

*Enfin, **je dédie cette réussite à moi-même**, parce que je n'ai jamais abandonné malgré toutes les difficultés, et parce que j'ai continué mon chemin jusqu'à la fin.*

Mehala Ikram

ملخص

يُعدّ التعرف على النشاط البشري من المجالات التي شهدت اهتمامًا متزايدًا في السنوات الأخيرة، نظرًا لتطبيقاته المتعددة في مجالات الأمن، الرعاية الصحية، المراقبة الذكية، والأنظمة الذكية الحديثة. تعتمد العديد من الأنظمة التقليدية على الكاميرات أو الحساسات القابلة للارتداء، إلا أن هذه الوسائل قد تعاني من بعض القيود المتعلقة بالخصوصية أو ضعف الأداء في البيئات المعقدة. لذلك، أصبح من الضروري تطوير حلول أكثر فعالية تعتمد على معالجة الإشارات وتقنيات الذكاء الاصطناعي. يهدف هذا العمل إلى دراسة وتصنيف الحركات البشرية انطلاقًا من إشارات النشاط الحركي، سواء كانت صادرة عن شخص واحد أو مجموعة من الأشخاص. تعتمد الدراسة على تحويل الإشارات إلى تمثيلات زمنية-ترددية تسمح بإظهار الخصائص المميزة لكل حركة بشكل واضح وقابل للتحليل.

في هذا السياق، تم استخدام عدة طرق للتحليل الزمن-ترددية، والمتمثلة في : Spectrogramme و PCBD و EMBD و SST ، حيث تسمح هذه الطرق بتحويل الإشارات إلى صور طيفية تحتوي على معلومات مهمة تساعد في التمييز بين الحركات المختلفة. بعد ذلك، خضعت البيانات لمرحلة معالجة مسبقة تضمنت إعادة تحجيم الصور وتحسينها، بالإضافة إلى تطبيق تقنيات زيادة البيانات (Data Augmentation) بهدف تحسين جودة قاعدة البيانات وتقليل مشكلة فرط التعلم. من أجل عملية التصنيف، تم الاعتماد على نموذجين من الشبكات العصبية الالتفافية (CNN) ، وهما InceptionV3 و ResNet101V2، وذلك في إطار التعلم بالنقل (Transfer Learning) لاستخراج الخصائص العميقة من الصور الطيفية. كما تم دمج كل نموذج مع شبكة الذاكرة طويلة وقصيرة المدى (LSTM) للاستفادة من قدرتها على تحليل العلاقات الزمنية بين الخصائص المستخرجة وتحسين أداء التصنيف..

أظهرت النتائج التجريبية فعالية النماذج المقترحة في التعرف على الحركات البشرية وتصنيفها بدقة مرتفعة، مما يؤكد أن الدمج بين التحليل الزمن-ترددية وتقنيات التعلم العميق الحديثة يساهم بشكل كبير في تحسين أداء أنظمة التعرف على النشاط البشري.

الكلمات المفتاحية: تصنيف الحركات البشرية، إشارات الميكرو-دوبلر، التحليل الزمن-ترددية، التعلم العميق، نموذج الشبكة العصبية التلافيفية (CNN)، نموذج الذاكرة طويلة المدى (LSTM).

Résumé

La reconnaissance de l'activité humaine est devenue un domaine de recherche très important ces dernières années en raison de ses nombreuses applications dans les domaines de la sécurité, de la santé, de la surveillance intelligente et des systèmes modernes. Les systèmes traditionnels reposent généralement sur des caméras ou des capteurs portables, mais ces solutions présentent certaines limites liées à la confidentialité et à la diminution des performances dans des environnements complexes. Ainsi, il est devenu nécessaire de développer des solutions plus efficaces basées sur le traitement du signal et les techniques d'intelligence artificielle. Ce travail vise à étudier et classifier les mouvements humains à partir des signaux d'activité, qu'ils proviennent d'une seule personne ou d'un groupe de personnes. L'étude repose sur la transformation des signaux en représentations temps-fréquence permettant de mettre en évidence les caractéristiques distinctives de chaque mouvement de manière claire et exploitable.

Dans ce contexte, plusieurs méthodes d'analyse temps-fréquence ont été utilisées notamment : Spectrogramme, PCBD, EMBD et SST. Ces méthodes permettent de transformer les signaux en images spectrales contenant des informations importantes facilitant la distinction entre les différents mouvements. Ensuite, les données ont subi une phase de prétraitement comprenant le redimensionnement et l'amélioration des images, ainsi que l'application des techniques de Data Augmentation afin d'améliorer la qualité de la base de données et de réduire le problème du Surapprentissage. Pour la phase de classification, des techniques d'apprentissage profond (deep learning) ont été utilisées, en particulier un type de réseaux de neurones convolutifs (CNN), InceptionV3 et ResNet101V2, ont été exploitées dans le cadre du transfert d'apprentissage pour l'extraction automatique des caractéristiques profondes à partir des représentations temps-fréquence. Par la suite, ces modèles ont été combinés avec un réseau LSTM afin de prendre en compte les dépendances temporelles entre les caractéristiques extraites et d'améliorer les performances de classification.

Les résultats expérimentaux obtenus ont montré l'efficacité des Modèles proposés dans la reconnaissance et la classification des mouvements humains avec une grande précision, ce qui confirme que la combinaison de l'analyse temps-fréquence et des techniques modernes d'apprentissage profond contribue considérablement à l'amélioration des systèmes de reconnaissance de l'activité humaine.

Mots-clés: Classification des mouvements humains, signaux micro-Doppler, Analyse temps-fréquence, apprentissage profond, réseaux de neurones convolutifs, Modèle CNN, Modèle LSTM.

Abstract

Human Activity Recognition (HAR) has become an important research field in recent years due to its numerous applications in security, healthcare, intelligent surveillance, and modern smart systems. Traditional systems generally rely on cameras or wearable sensors; however, these solutions suffer from several limitations related to privacy issues and reduced performance in complex environments. Therefore, developing more efficient solutions based on signal processing and artificial intelligence techniques has become necessary. This work aims to study and classify human movements using activity signals generated either by a single person or by a group of people. The study is based on transforming the signals into time-frequency representations that highlight the distinctive characteristics of each movement in a clear and exploitable manner.

In this context, several time-frequency analysis methods were used, namely: Spectrogram, PCBD, EMBD, and SST. These methods transform the signals into spectral images containing important information that facilitates the discrimination between different movements. Afterwards, the data underwent a preprocessing stage including image resizing and enhancement, in addition to the application of Data Augmentation techniques to improve the quality of the dataset and reduce the Overfitting problem. For the classification phase, two Convolutional Neural Network (CNN) architectures, InceptionV3 and ResNet101V2, were employed using a transfer learning approach to automatically extract deep features from the time-frequency representations. Subsequently, these models were combined with a Long Short-Term Memory (LSTM) network to capture temporal dependencies among the extracted features and enhance classification performance.

The experimental results demonstrated the effectiveness of the Proposed Models in recognizing and classifying human movements with high accuracy, confirming that the combination of time-frequency analysis and modern deep learning techniques significantly enhances Human Activity Recognition systems.

Keywords: Human movement classification, micro-Doppler signals, time-frequency analysis, deep learning, convolutional neural networks, CNN model, LSTM model.

Table of Contents

Chapitre I	4
I.1 Introduction	4
I.2 Historique	4
I.3.1 Définition du radar Doppler	5
I.3.2 Réflexion des ondes et effet Doppler sur le corps humain	5
I.4 Effet Doppler	6
I.4.1 Définition	6
I.4.2 Les types du décalage Doppler «Différents cas d'effet Doppler »	6
I.4.2.1 Définition	6
I.4.2.2 Source et observateur immobiles	6
I.4.2.3 Source en mouvement	7
I.4.2.3.1 Source s'éloignant et observateur immobile	8
I.4.2.3.2 Source s'approche et observateur immobile	8
I.4.2.4 Récepteur en mouvement	9
I.4.3 Paramètres Influençant le décalage Doppler	9
I.4.4 Applications de l'effet Doppler	10
I.5 Effet micro-Doppler	11
I.5.1 Définition	11
I.5.2 La signature	11
I.5.3 Applications du micro-Doppler	12
I.5.3.1 Application courante	12
I.5.3.2 Applications émergentes	13
I.6 Conclusion	13
Chapitre II	15
II.1 Introduction	15
II.2.1 Transformée de Fourier à Court Terme (STFT)	16
II.2.1.1 Définition et principe	16
II.2.1.2 Fenêtres	17
II.2.1.3 Propriétés de la STFT	17
II.2.1.4 Limites de la STFT	18
II.2.2 L'analyse temps-échelle « Transformée en ondelette »	18
II.2.2.1 Définition et principe	18
II.2.2.2 Limitations de la Transformé en ondelette	19

II.2.3 La transformée Synchrosqueezing	20
II.2. 3.1 définition	20
II.3 Les représentations temps-fréquence quadratique	21
II.3.1 Spectrogramme	21
II.3.1.1 Définition	21
II.3.1.2 Propriétés	21
II.3.1.3 Résolution temps fréquence.....	21
II.3.2 Distribution de Wigner-Ville.....	22
II.3.2.1 Définition et principe	22
II.4 Les distributions basées sur les noyaux	23
II.4.1 Le noyau CB Polynomial (PCB)	23
II.4.2 Distribution B modifiée et distribution B modifiée Elargie.....	25
a. Distribution B modifiée	25
b. Distribution B modifiée Elargie	25
II.5 Conclusion	26
Chapitre III	28
III.1 Introduction	28
III.2 Description de la base de données	28
III.3 Apprentissage profond	35
III.3.1 Réseaux de Neurones Convolutifs (CNN).....	35
III.3.2 Les LSTM (Long Short-Term Memory)	37
III.3.3 Modèles utilisés pour la première approche	39
a. InceptionV3	39
b. ResNet101V2	39
III.3.4 Modèles utilisés pour la deuxième approche.....	41
III.4 Augmentation des données	42
III. 5 Description de la préparation expérimentale.....	43
III.6 Evaluation des métriques	47
III.7 Conclusion	48
Chapitre IV	50
IV.1 Introduction	50
IV.2 L'environnement de travail et les outils utilisés	50
IV.2.1 Matériel	50
IV.2.2 Langage de programmation	50

IV.2.3 Bibliothèques utilisées	51
IV.3 Résultats expérimentaux et évaluation.....	52
IV.3.1 Résultats obtenus pour la première Classification « Sans LSTM ».....	53
IV.3.2 Discussion	59
IV.3.3 Résultats obtenus pour la deuxième Classification « Avec LSTM ».....	60
IV.3.4 Discussion	66
IV.4 Conclusion	67
Conclusions Générale	68
Recommandations et Perspectives pour les Travaux Futurs.....	69

Liste des abréviations

S	Source
R	Récepteur
Vr	Vitesse de récepteur
Vs	Vitesse de source
TF	Transformée de Fourier
DTF	Distribution Temps–Fréquence
STFT	Short Time Fourier Transform
CWT	Continuous Wavelet Transform
WVD	Distribution de Wigner-Ville
DTF	Distributions Temps-Fréquence
KCS	Compact Support Kernel
PCB	Noyau de Cheriet-Belouchrani Polynomial
EMBD	Extended Modified B Distribution
SST	Synchrosqueezing Transform
CNN	Convolutional Neural Network
LSTM	Long Short-Term Memory
ResNet101V2	Residual Network 101Version 2
InceptionV3	Inception Version 3

Liste des figures

Chapitre I

Figure I.1: Christian doppler.....	4
Figure I.2: Buys-Ballot.....	4
Figure I.3: Radr doppler	5
Figure I.4: Les ondes électromagnétiques actions et effets sur le corps humain	5
Figure I.5: Effet doppler	6
Figure I.6: Source et observateur immobiles	6
Figure I.7: Propagation de l'onde (cas immobiles)	7
Figure I.8: Source en mouvement (effet doppler)	7
Figure I.9: Variation de l'onde (Effet Doppler)	7
Figure I.10: Effet doppler (source s'approche et s'éloigne)	8
Figure I.11: Le décalage vers le rouge et vers le bleu	10
Figure I.12: Une ambulance	10
Figure I.13: Effet doppler et micro-doppler	11
Figure I.14: Echographie doppler	13
Figure I.15: Micro Rain Radar (MRR).....	13

Chapitre II

Figure II.1 Représentation temporelle	14
Figure II.2 Représentation fréquentielle	14
Figure II.3 Analyse temps-fréquence utilisant la transformée de Fourier à court terme	15
Figure II.4 Fenêtre longue.....	17
Figure II.5 Fenêtre courte	17
Figure II.6 Transformée en ondelette continue a l'échelle $a=5$	18
Figure II.7 La CWT d'un train d'impulsions périodique	19
Figure II.8 Une résolution parfaite avec STFT en temps avec impulsion de Dirac.....	21
Figure II.9 Une résolution parfaite en fréquence.....	21
Figure II.10 Localisation des autos termes du signal et des termes d'interférence	23
Figure II.11 Profil KCS bidimensionnel pour une bande passante fixe (plan du décalage temporel et plan du délai doppler)	23

Chapitre III

Figure III.1 : Organisation de la base donnée utilisée	27
Figure III.2 Analyse temps-fréquence par la méthode spectrogramme des signatures micro-doppler (A) Une personne qui marche (B) Une personne qui court.....	28
Figure III.3 Analyse temps-fréquence par la méthode PCBD des signatures micro-doppler (A) une personne qui marche et (B) une personne qui court.....	28
Figure III.4 Analyse temps-fréquence par la méthode EMBD des signatures micro-doppler (A) une personne qui marche (B) une personne qui court	29

Figure III.5 Analyse temps-fréquence par la méthode SST des signatures micro-doppler (A) une personne qui marche (B) une personne qui court	29
Figure III.6 Analyse temps-fréquence par la méthode spectrogramme des signatures micro-doppler (A) un groupe de personnes (B) un groupe de personnes courant	30
Figure III.7 Analyse temps-fréquence par la méthode PCBD des signatures micro-doppler (A) un groupe de personnes et (B) un groupe de personnes courant	32
Figure III.8 Analyse temps-fréquence par la méthode EMBD des signatures micro-doppler (A) un groupe de personnes marchant et (B) un groupe de personnes courant	33
Figure III.9 Analyse temps-fréquence par la méthode SST des signatures micro-doppler (A) un groupe de personnes marchant et (B) un groupe de personnes courant	33
Figure III.10 Les couches d'un réseau de neurones convolutif (CNN).....	35
Figure III.11 Couche convolutionnelle.....	36
Figure III.12 Couche Pooling	36
Figure III.13 Fully connecte	36
Figure III.14 Composant d'une cellule LSTM	37
Figure III.15 Porte d'oubli.....	37
Figure III.16 Porte d'entrée	38
Figure III.17 Fonction d'activation sigmoïde (a) et (b) tangente hyperbolique.....	35
Figure III.18 Porte sortie.....	35
Figure III.19 Convolution factorisées.....	36
Figure III.20 Architecture d'inceptionV3	39
Figure III.21 Architecture de ResNet101V2	37
Figure III.22 Architecture des modèles hybrides	38
Figure III.23 Ensemble des images avant augmentation	39
Figure III.24 Ensemble des images après augmentation	39
Figure III.25 Architecture globale du système de classification des mouvements humains.....	42
Figure III.26 (A) Architecture pratique du inceptionV3 de sans LSTM et (B) Architecture pratique du ResNet101V2 sans LSTM.....	42
Figure III.27 (A) Architecture pratique de l'inceptionV3 avec LSTM et (B) Architecture pratique du ResNet101V2 avec LSTM	43
Figure III.28 La matrice de confusion	44

Chapitre IV

Figure IV.1 : Google Colab logo	47
Figure IV.2 : Python Logo	47
Figure IV.3 : TensorFlow Logo	48
Figure IV.4 : OpenCV Logo	48
Figure IV.5 : Keras Logo	48
Figure IV.6 : Keras Logo	48
Figure IV.7 : Keras Logo	48
Figure IV.8 : Matplotlib et Seaborn Logo.....	48
Figure IV.9 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode Spectrogramme Du modèle InceptionV3	54
Figure IV.10 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode PCBD Du modèle InceptionV3.....	54

Figure IV.11 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode EMBD Du modèle InceptionV3.....	54
Figure IV.12 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode SST Du modèle InceptionV3	54
Figure IV.13 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode Spectrogramme Du modèle ResNet101V2.....	55
Figure IV.14 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode PCBD Du modèle ResNet101V2	55
Figure IV.15 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode EMBD Du modèle ResNet101V2	56
Figure IV.16 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode SST Du modèle ResNet101V2	56
Figure IV.17 : Matrice de Confusion Pour la méthode de Spectrogramme	57
Figure IV.18 : Matrice de Confusion Pour la méthode de PCBD	57
Figure IV.19 : Matrice de Confusion Pour la méthode d'EMBD	54
Figure IV.20 : Matrice de Confusion Pour la méthode De SST.....	58
Figure IV.21 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode Spectrogramme Du modèle InceptionV3+LSTM.....	57
Figure IV.22 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode PCBD Du modèle InceptionV3+LSTM	57
Figure IV.23 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode EMBD Du modèle InceptionV3+LSTM	61
Figure IV.24 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode SST Du modèle InceptionV3+LSTM.....	57
Figure IV.25 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode Spectrogramme Du modèle ResNet101V2+LSTM	58
Figure IV.26 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode PCBD Du modèle ResNet101V2+LSTM.....	59
Figure IV.27 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode EMBD Du modèle ResNet101V2+LSTM.....	59
Figure IV.28 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode SST Du modèle ResNet101V2+LSTM	59
Figure IV.29 : Matrice de Confusion Pour la méthode de Spectrogramme	60
Figure IV.30 : Matrice de Confusion Pour la méthode de PCBD	61
Figure IV.31 : Matrice de Confusion Pour la méthode d'EMBD	65
Figure IV.32 : Matrice de Confusion Pour la méthode de SST.....	66

Liste des tableaux

Chapitre I

Tableau I.1 Variation de la fréquence de la longueur d'onde (effet doppler).....	8
Tableau I.2 Illustration de différentes activités humaines	11

Chapitre III

Tableau III.1 Paramètres du système radar et organisation des données.....	26
Tableau III.2 Résumé des architectures des modèles utilisés [15] [14].....	37
Tableau III.3 Les paramètres d'augmentation	39
Tableau III.4 Présentation des exemples des images avant et après l'augmentation des données.....	43
Tableau III.5 Paramètres d'entraînement des modèles.....	44
Tableau III.6 Répartition des images par classe avant et après découpage	44
Tableau III.7 Répartition des images par classe après augmentation.....	45
Tableau III.8 Caractéristiques techniques des paramètres des modèles	45
Tableau III.9 Caractéristiques techniques des paramètres des modèles Hybride.....	46

Chapitre IV

Tableau IV.1 Caractéristiques du matériel utilisé pour le calcul physique	47
Tableau IV.2 Présente les performances obtenues pour les modèles InceptionV3 et ResNet101V2 des quatre méthodes d'analyse temps fréquence	49
Tableau IV.3 Le temps d'entraînement total et le temps Inférence de chaque modèle	49
Tableau IV.4 Présente les performances obtenues pour les modèles Hybride des quatre méthodes d'analyse temps fréquence	56
Tableau IV.5 Le temps d'entraînement total et le temps Inférence de chaque modèle Hybride.....	56

Introduction générale

L'étude des mouvements humains représente aujourd'hui un axe de recherche très actif, en raison de son importance dans plusieurs domaines tels que la surveillance intelligente, la sécurité, la santé et la reconnaissance automatique des activités. Dans ce cadre, les radars Doppler et les signaux micro-Doppler constituent une solution efficace permettant d'analyser les mouvements humains sans recourir aux systèmes de vision classique, particulièrement dans des environnements difficiles comme les faibles conditions d'éclairage ou les scènes encombrées.

Les activités humaines telles que la marche et la course génèrent des signatures micro-Doppler spécifiques qui traduisent le comportement dynamique des différentes parties du corps. L'exploitation de ces signatures devient encore plus complexe lorsqu'il s'agit d'analyser une personne isolée ou un groupe d'individus, ce qui nécessite des méthodes robustes capables de distinguer efficacement les différents types de mouvements. Étant donné que les signaux micro-Doppler sont de nature non stationnaire, leur analyse repose principalement sur des outils temps-fréquence permettant de suivre l'évolution du contenu fréquentiel au cours du temps et d'en extraire les informations pertinentes liées à chaque mouvement.

Dans ce travail, plusieurs représentations temps-fréquence sont exploitées afin d'évaluer leur capacité à représenter efficacement les caractéristiques des mouvements humains.

L'objectif de cette étude est de concevoir un système de reconnaissance automatique capable d'identifier les mouvements de marche et de course, aussi bien pour un individu seul que pour des groupes de personnes, à partir des signaux micro-Doppler. Pour cela, quatre représentations temps-fréquence sont générées et étudiées, à savoir : le Spectrogram, la Synchrosqueezing, la distribution EMBD et la distribution PCBD. L'objectif est d'analyser leur influence sur les performances globales du système et de déterminer la plus performante.

Par la suite, des méthodes d'apprentissage profond sont utilisées pour l'extraction automatique des caractéristiques et la classification. Les modèles InceptionV3 et ResNet101V2 sont exploités pour extraire des descripteurs à partir des images issues des représentations temps-fréquence. En complément, un modèle hybride combinant les réseaux convolutifs (CNN) et les réseaux LSTM est proposé afin de tirer profit à la fois des informations spatiales et temporelles. Le réseau LSTM est également utilisé pour effectuer la phase finale de classification. Des techniques d'augmentation de données sont appliquées afin d'améliorer la robustesse du modèle et d'augmenter sa capacité de généralisation, notamment en raison du nombre limité d'échantillons disponibles.

L'objectif principal de ce travail est de réaliser une comparaison entre différentes représentations temps-fréquence et d'analyser leur impact sur les performances de détection et de classification des mouvements humains à partir des signaux micro-Doppler, afin d'identifier la méthode la plus adaptée.

Le présent mémoire est structuré comme suit :

- ❖ Le premier chapitre présente les notions fondamentales liées aux signaux Doppler et micro-Doppler.
- ❖ Le deuxième chapitre est consacré à l'étude des techniques d'analyse temps-fréquence des signaux non stationnaires en faisant un tour d'horizon sur les techniques linéaires, quadratiques et celles basées sur la notion du noyau.

- ❖ Le troisième chapitre décrit la méthodologie de classification adoptée, incluant la base de données, les techniques de Data Augmentation, les modèles de Deep Learning (InceptionV3 et ResNet101V2), le modèle hybride CNN-LSTM.
- ❖ Le quatrième chapitre présente les résultats expérimentaux ainsi que leur étude comparative entre les quatre méthodes d'analyse (Spectrogramme, Synchrosqueezing, EMBD et PCBD).

Enfin, une conclusion générale synthétise les principaux résultats obtenus et propose quelques perspectives pour des travaux futurs.

Chapitre I

Effet Doppler et Micro-Doppler

Chapitre I

I.1 Introduction

Aujourd'hui, la technologie radar ne se limite plus à la détection et à l'analyse des mouvements des objets, mais s'étend également à l'étude du mouvement humain et à la caractérisation précise de leurs comportements. Ce développement technologique repose sur l'effet Doppler, un phénomène physique découvert par « Christian Doppler en 1842 », qui établit un lien entre la variation de fréquence réfléchie et le déplacement relatif de l'objet, permettant ainsi d'estimer avec précision la vitesse élevée des cibles.

L'analyse du mouvement humain s'appuie sur le traitement des signaux électromagnétiques réfléchis. Elle ne se contente plus de déterminer la vitesse globale du corps via l'effet Doppler traditionnel, mais intègre désormais le phénomène micro-Doppler. Ce phénomène permet de révéler les signatures fines du mouvement humain, appelées signatures micro-Doppler résultant des oscillations des membres, des vibrations thoraciques liées à la respiration ou d'autres détails biomécaniques subtils.

I.2 Historique

Le nom de l'effet Doppler vient du mathématicien et physicien autrichien Christian Johann Doppler (1803-1853), qui a théorisé ce principe en 1842. Son étude initiale portait sur les ondes sonores, mais le concept s'étend bien au-delà, aux ondes électromagnétiques comme la lumière, et est utilisé dans une multitude d'applications scientifiques et technologiques (Figure 1.1).

L'existence de l'effet n'a pu être confirmée que par des expériences réalisées quelques années plus tard, notamment l'expérience quelque peu rocambolesque mise sur pied en 1845 par néerlandais Buys-Ballot (1817-1890), qui a fait jouer des Trompettistes sur une locomotive en mouvement devant des Observateurs musiciens (Figure 1.2).

Que l'effet Doppler n'ait pas été découvert plus tôt dans l'Histoire peut s'expliquer simplement par le fait qu'il n'existait pas de moyens de déplacement assez rapides pour que l'effet Doppler sonore puisse être constaté. De plus, le concept de l'électromagnétisme qui permet de se représenter la lumière comme une onde n'a été développée qu'au XIX^e siècle difficile donc à cette époque d'interpréter les décalages Doppler de la lumière venant du ciel [1].



Figure I.1 : Christian Doppler [57]




Figure I.2 : Buy Ballot [58]

I.3 Radar Doppler

I.3.1 Définition du radar Doppler

Un radar Doppler est un radar qui utilise l'effet Doppler-Fizeau de l'écho réfléchi par une cible pour mesurer sa vitesse radiale. Le signal micro-onde émis par l'antenne directionnelle du radar est réfléchi par la cible et comparé en fréquence avec le signal original allé et retour.

Il permet ainsi une mesure directe et extrêmement précise de la composante vitesse de la cible dans l'axe du faisceau. Les radars Doppler sont utilisés pour la défense aérienne, pour le contrôle du trafic aérien, pour la surveillance des satellites, pour le contrôle de vitesse sur route, en radiologie et dans les réseaux d'assainissement (Figure I.3) [2].




Figure I.3 : Radar Doppler [59]

I.3.2 Réflexion des ondes et effet Doppler sur le corps humain

Les ondes, qu'elles soient sonores ou électromagnétiques, interagissent avec le corps humain lorsqu'elles rencontrent ses tissus de densités différentes (peau, muscles, os). Une partie de l'énergie incidente est absorbée, réfléchie ou transmise. Lorsqu'un sujet est en mouvement, chaque segment du corps induit un déphasage spécifique de l'onde réfléchie, générant un effet Doppler. Cette modulation permet de traduire les micro-mouvements (respiration, oscillation des bras...ect) en informations fréquentielles exploitables pour caractériser précisément la vitesse et la nature du mouvement humain (Figure I.4) [3].




Figure I.4 : Les ondes électromagnétiques actions et effets sur le corps humain [3]

I.4 Effet Doppler

I.4.1 Définition

L'effet Doppler correspond à la variation apparente de la fréquence d'un signal sonore ou électromagnétique reçu par un observateur qui se déplace par rapport à une source émettrice stationnaire, ou bien pour un observateur fixe face à une source émettrice en mouvement [4].

L'effet Doppler indique que le changement visible de fréquence est directement lié à la vitesse relative entre l'observateur et la source sur la trajectoire qui les unit (Figure 1.5).




Figure 1.5 : Effet Doppler [60]

I.4.2 Les types du décalage Doppler «Différents cas d'effet Doppler »

I.4.2.1 Définition

On appelle « décalage Doppler » symbolisée par δf , se réfère à la différence en termes absolus entre la fréquence de l'onde réceptionnée et celle de l'onde émise [5].

$$\delta f = |f_{\text{émise}} - f_{\text{reçue}}| \quad (\text{I.1})$$

I.4.2.2 Source et observateur immobiles

Considérons une source sonore S située à égale distance de deux observateurs A et B . La source génère une onde acoustique de fréquence f (et de période T) qui se déplace dans l'air à la vitesse V_o . La relation suivante donne sa longueur d'onde (Figure I.6) [6].

$$\lambda = V_o \cdot T = \frac{V_o}{f} \quad (\text{I.2})$$




Figure I.6 : Source et observateur immobiles [6]

L'onde affecte au même instant les deux observateurs simultanément. Ils perçoivent tous les deux une onde sonore de fréquence f et de longueur d'onde λ (Figure I.7) [5].




Figure I.7 : Propagation de l'onde (cas immobiles) [5]

I.4.2.3 Source en mouvement

La source se déplace maintenant vers l'observateur **B** à une Vitesse V_s s'éloignant ainsi de L'observateur **A** (Figure I.8).




Figure I.8 : Source en mouvement (effet Doppler) [6]

Selon la Figure I.9, l'observateur **A** capte une onde de longueur d'onde et donc de période plus grande que celle de l'onde émise par la source. L'observateur **B** capte une onde de longueur d'onde et donc de période plus petite que celle de l'onde émise par la source [6].

$$\text{Observateur A : } \lambda_A = \lambda + V_s T$$

$$\text{Observateur B : } \lambda_B = \lambda - V_s T \quad (I.3)$$




Figure I.9: Variation de l'onde (Effet Doppler) [6]

I.4.2.3.1 Source s'éloignant et observateur immobile

$$\text{Observateur A} \Rightarrow (\lambda_A = \lambda + V_s T) : \quad (I.4)$$

Si V_s est petite devant V_o :

$$\Rightarrow f_a = f \left(1 - \frac{V_s}{V_o} \right) \Rightarrow f_a < f \quad (I.5)$$

Lorsque la source sonore s'éloigne d'un observateur **A** la fréquence f_a perçue par l'observateur **A** est inférieure à la fréquence f de la source sonore (le son est plus grave) (Figure I.10) [6].

I.4.2.3.2 Source s'approche et observateur immobile

$$\text{Observateur B} \Rightarrow (\lambda_B = \lambda - V_s T) : \quad (I.6)$$

Si V_s est petite devant V_o :

$$\Rightarrow f_b = f \left(1 + \frac{V_s}{V_o} \right) \Rightarrow f_b > f \quad (I.7)$$

Lorsque la source sonore s'approche d'un Observateur **B** la fréquence f_b perçue par l'observateur **B** est supérieure à la fréquence f de la source sonore (le son est plus aigu) (Figure I.10) [6].




Figure I.10 : Effet doppler (source s'approche et s'éloigne) [5]

	La source et Le récepteur...	Le récepteur...
	...se rapprochent	...s'éloignent
Fréquence	$f_{reçue} > f_{émise}$	$f_{reçue} < f_{émise}$
Longueur d'onde	$\lambda_{reçue} < \lambda_{émise}$	$\lambda_{reçue} > \lambda_{émise}$

Tableau I.1: Variation de la fréquence et de la longueur d'onde (Effet Doppler)

I.4.2.4 Récepteur en mouvement

Lorsqu'un émetteur en mouvement produit une onde, l'onde se déplace à la vitesse V_o caractérisée par le milieu. Par contre la vitesse V' de l'onde par rapport au récepteur sera perçue différemment si le récepteur est en mouvement à la vitesse V_r . Supposons : $V_r < V_o$ alors [6].

Récepteur s'approche de l'onde

Récepteur s'éloigne de l'onde

$$V' = V_o + V_r \text{ (Vitesse de l'onde augmente)} \quad V' = V_o - V_r \text{ (Vitesse de l'onde diminue)}$$

Lorsqu'un récepteur mesure la vitesse V' d'une onde par rapport à lui-même, celle-ci est influencée par la vitesse du récepteur. Cette relation est valide seulement lorsque la vitesse V_r du récepteur est inférieure à la vitesse de propagation de l'onde V_o [6].

$$V' = V_o \pm V_r \quad (I.8)$$

Où :

V' : Vitesse de l'onde par rapport au récepteur (m/s)

V_o : Vitesse de l'onde dans son milieu (m/s)

V_r : Vitesse du récepteur (m/s)

$\pm$: (Positif :+) Récepteur fonce vers l'onde (augmentation de la vitesse)

$\pm$: (Négatif :−) Récepteur se sauve de l'onde (diminution de la vitesse)

I.4.3 Paramètres Influençant le décalage Doppler

Type d'onde : L'effet Doppler concerne tous les types d'ondes mais son comportement dépend du milieu et de la vitesse de l'onde [7].

Mouvement relatif : L'amplitude du décalage est directement proportionnelle à la vitesse relative entre la source et le récepteur. L'effet perçu atteint son intensité maximale lorsque cette vitesse est significative par rapport à la célérité de l'onde [7].

Propriétés du milieu : Pour les ondes acoustiques en particulier, les conditions environnementales telles que la température, la densité et la pression du fluide modifient la vitesse de propagation, ce qui impacte directement la variation de fréquence perçue [7].

I.4.4 Applications de l'effet Doppler

I.4.2.1 Astronomie

L'effet Doppler est utilisé en astronomie pour mesurer la vitesse à laquelle les étoiles ou les galaxies se rapprochent ou s'éloignent de nous, c'est-à-dire leur vitesse radiale. Cela permet souvent de déterminer si un objet se déplace vers ou loin de l'observateur. Ceci est fait en observant le décalage vers le rouge (éloignement) ou vers le bleu (rapprochement) des raies spectrales de l'objet (Figure I.11) [8].




Figure I.11 : Le décalage vers le rouge et vers le bleu [8]

I.4.2.2 Ingénierie sonore

L'effet Doppler est utilisé en ingénierie sonore pour créer l'illusion de mouvement dans les enregistrements et les performances.

Comme l'exemple de « la sirène d'ambulance » l'ambulance s'approche, les ondes sonores se compriment, ce qui fait augmenter la fréquence perçue (le son paraît plus aigu). Lorsqu'elle s'éloigne, les ondes se dilatent, entraînant une baisse de la fréquence perçue (le son devient plus grave) (Figure I.12) [7].




Figure I.12 : Exemple de l'effet Doppler : Une ambulance [61]

I.5 Effet micro-Doppler

I.5.1 Définition

Lorsqu'un objet subit des déformations en plus de son déplacement global, le signal radar réfléchi est modulé en fréquence. C'est parce que les parties déformables ont des vitesses radiales différentes de la vitesse de déplacement de la cible, ce qui se traduit sur le spectre Doppler par un étalement des fréquences autour de la fréquence Doppler centrale. Cette modulation de fréquence est appelée effet micro-Doppler (Figure I .13) [9].




Figure I .13 : Effet Doppler et micro-Doppler [62]

Les sources de mouvement qui génèrent l'effet micro-Doppler sont variées. Les plus courantes sont les rotations des roues, des pales d'hélicoptères, d'antennes tournantes, des turbines d'avions, ainsi que les vibrations de structures. Activités humaines est également intéressant car les bras et les jambes ont un mouvement propre, indépendant de celui du corps [10].

I.5.2 La signature

Les signatures micro-Doppler sont des variations de fréquence du signal radar réfléchi, qui sont liées aux mouvements d'objets ou de personnes dans le champ de détection. Ces variations dépendent de la vitesse et de la direction du mouvement. Lorsqu'on parle de la détection des mouvements humains, La signature Doppler précise permet d'identifier un objet grâce à ses mouvements [11].

Lors de toute activité humaine, le mouvement des différentes parties du corps génère des oscillations dans le signal d'écho radar. Différentes activités humaines affectent différemment ce signal « marche, course, geste spécifique » générant ainsi des signatures de mouvement précises distinctes [12].

Activité	Description
Marche 	Une personne qui marche produit un profil Doppler régulier à basse fréquence, avec de légères variations dues aux mouvements du corps, des bras et des jambes elle comprend : <ul style="list-style-type: none"> - La marche normale - La marche lente - La marche en s'éloignant et se rapprochant de la cible
Cours 	Une personne qui court présente des pics plus fréquents et des oscillations de fréquence plus marquées, dues à sa vitesse et à l'amplitude de ses gestes elle comprend : <ul style="list-style-type: none"> - La course normale - Le jogging - La course en s'éloignant et se rapprochant de la cible
Gestes spécifiques	Quand une personne lève le bras ou effectue un mouvement rapide, la fréquence Doppler augmente et varie en fonction de la direction et de l'ampleur du geste.

Tableau I.2 : Illustration de différentes activités humaines

I.5.3 Applications du micro-Doppler


Le micro-Doppler, qui analyse les micro-mouvements (vibrations, rotations) en plus de la vitesse globale, est crucial pour la classification d'objets et la reconnaissance d'activités.

I.5.3.1 Application courante

Médicale : L'échographie Doppler est un examen médical échographique en deux dimensions non Invasives qui permet d'explorer les flux sanguins intracardiaques et intra vasculaires. Elle est basée sur un phénomène physique des ultrasons: l'effet Doppler. Elle est souvent surnommée écho Doppler. (Figure I .14) [13].

Sécurité : L'effet micro-doppler peut être utilisé pour détecter des mouvements suspects dans une zone surveillée. Cela peut être utile pour la sécurité des bâtiments ou des infrastructures critiques.[14]

Météorologie : Le MRR Micro-Rain-Radar à 24 GHz est un radar météorologique Metek unique pour la mesure par spectres Doppler de présence d'hydrométéores sur une colonne verticale de 15 m à 6000 m (Figure I .15) [15].

**Figure I.14** : Echographie Doppler [13]**Figure I.15** : Micro Rain Radar (MRR) [15]

I.5.3.2 Applications émergentes

Parmi les applications émergentes de l'IA, la classification non intrusive des mouvements humains – marcher, s'asseoir ou tomber – grâce aux radars à ondes millimétriques ouvre de nouvelles perspectives pour l'habitat intelligent et la télésurveillance [16].

I.6 Conclusion

En conclusion, l'effet Doppler est un phénomène essentiel dans l'étude des ondes. Il permet, notamment dans les systèmes radar, d'estimer la vitesse des cibles en mouvement grâce à la variation de fréquence causée par le mouvement relatif entre la source et l'observateur.

Toutefois, les cibles réelles présentent souvent des mouvements internes complexes, ce qui a conduit à l'introduction du concept de micro-Doppler, offrant une description plus fine et détaillée des signatures générées.

Ainsi, l'étude conjointe de l'effet Doppler et du micro-Doppler met en évidence la nature intrinsèquement non stationnaire des signaux observés. Cette complexité rend les méthodes d'analyse classiques insuffisantes pour une description complète de ces phénomènes.

Par conséquent, il devient indispensable de recourir à des outils d'analyse plus adaptés, capables de représenter simultanément l'évolution temporelle et fréquentielle du signal. C'est dans ce cadre que s'inscrit l'analyse temps-fréquence, qui fera l'objet du chapitre suivant, en offrant des approches performantes pour l'étude et l'interprétation des signatures Doppler et micro-Doppler.

Chapitre II

L'analyse temps-fréquence

Chapitre II

II.1 Introduction

L'analyse des signaux constitue un domaine essentiel dans le traitement du signal, où différentes représentations sont utilisées afin de mieux comprendre leurs caractéristiques. Les approches classiques, telles que la représentation temporelle ou fréquentielle, permettent chacune d'obtenir une vision partielle du signal.

Cependant, ces représentations prises séparément ne sont pas toujours suffisantes, notamment dans le cas des signaux non stationnaires, dont les caractéristiques évoluent au cours du temps. C'est dans ce contexte que les représentations temps-fréquence ont été développées, permettant une analyse conjointe en temps et en fréquence, et offrant ainsi une description plus riche et plus détaillée.

À titre d'illustration, considérons un signal à amplitude constante avec une modulation linéaire de la fréquence. Comme le montre la (Figure II.1) la représentation temporelle ne permet pas d'identifier clairement cette variation. De même, sa transformée de Fourier, présentée dans la (Figure III.2) fournit une information globale en fréquence sans indication sur son évolution dans le Temps. Ces limites justifient l'intérêt des méthodes d'analyse temps-fréquence.

Dans ce chapitre, nous présenterons les principales représentations temps-fréquence, en particulier les transformées linéaires ainsi que les représentations quadratiques, en mettant en évidence leurs principes et leurs caractéristiques [17].




Figure II.1 : Représentation temporelle [17]




Figure II.2 : Représentation fréquentielle [17]

Il existe plusieurs représentations temps-fréquence qui peuvent se diviser en deux catégories :

- 1- Les représentations temps-fréquence linéaires.
- 2- Les représentations temps-fréquence quadratique.

II.2 Les représentations temps-fréquence linéaires

II.2.1 Transformée de Fourier à Court Terme (STFT)

II.2.1.1 Définition et principe

La Transformée de Fourier à Court Terme (STFT), introduite par Dennis Gabor en 1946, est une méthode d'analyse temps-fréquence permettant de déterminer le contenu fréquentiel d'un signal au cours du temps. Elle consiste à appliquer la transformée de Fourier sur des portions locales du signal à l'aide d'une fenêtre temporelle glissante [18].

la STFT d'un signal $x(t)$ est définie par :

$$STFT_{x(t,f)} = \int_{-\infty}^{+\infty} x(\tau)w(\tau - t)e^{-j 2 \pi f \tau} d\tau \quad (II.1)$$

Où :

- $STFTx(t, f)$: est la représentation temps-fréquence du signal $x(t)$.
- $x(\tau)$: est le signal d'entrée,
- $w(\tau - t)$: est la fenêtre centrée autour de t qui sélectionne une portion locale du signal autour de t pour analyser la variation fréquentielle à ce moment précis
- $e^{-2j\pi f\tau}$: est le noyau de la Transformée de Fourier
- f : est la fréquence
- t : est le temps

Le principe de la STFT repose sur le découpage du signal en segments temporels de courte durée à l'aide d'une fonction fenêtre, puis sur l'application de la transformée de Fourier à chaque segment. Cette approche fournit une représentation conjointe du temps et de la fréquence [19].




Figure II.3 : Analyse temps-fréquence utilisant la transformée de Fourier à court terme [63]

La Figure II .3 représente le résultat de l'analyse du transformée de Fourier à court terme elle montre comment la fréquence change avec le temps. L'axe horizontal représente le temps, tandis que l'axe vertical représente la fréquence, et les couleurs indiquent l'intensité du signal. À travers cette image, on remarque que le signal passe par trois phases : au début, la fréquence est presque constante à environ 10 Hz, puis elle augmente entre 10 et 20 secondes à environ 20 Hz, et après 20 secondes

atteignent environ 30 Hz. Certaines lignes verticales apparaissent aux points de changement, ce qui est dû à la méthode d'analyse utilisée, car la transition ne se produit pas de manière complètement abrupte. Donc, cette image montre que la fréquence dans le signal change avec le temps et n'est pas constante.

II.2.1.2 Fenêtres

En général, la transformation est appliquée au produit entre le signal et une fenêtre. Ces fenêtres affectent toujours le spectre vu la modification de la définition de la transformée de fourrier. Il existe plusieurs types de fenêtres.

- **Fenêtre rectangulaire**

La fenêtre rectangulaire a d'excellentes caractéristiques de résolution pour des signaux possédant des amplitudes comparables, mais c'est un choix mauvais pour des signaux possédant des amplitudes disparates.

- **Fenêtres de Hamming et Hanning**

Les fenêtres de Hamming et Hanning sont généralement employées dans des applications à bande étroite, telles que le spectre d'un signal téléphonique. [20].

II.2.1.3 Propriétés de la STFT

La STFT présente un compromis entre la résolution temporelle et la résolution fréquentielle améliorer l'une entraîne une diminution de l'autre. La résolution temporelle permet de localiser un événement dans le temps, tandis que la résolution fréquentielle permet d'identifier les fréquences présentes dans le signal.

- **Une fenêtre plus longue** : capture plus de cycles d'oscillation, ce qui donne une meilleure résolution fréquentielle mais étale les événements sur un intervalle de temps plus large. (Figure II. 4)
- **Une fenêtre plus courte** : localise les événements avec précision dans le temps, mais floute le spectre fréquentiel car moins de cycles sont observés (Figure II .5)




Figure II.4: (Window length=3,3s)
Fenêtre longue [64]




Figure II.5: (Window length=1s)
Fenêtre courte [64]

Il n'est pas possible d'améliorer les deux simultanément. Chaque configuration STFT est un compromis [21].

II.2.1.4 Limites de la STFT

1. Résolution temps-fréquence fixe

Une fois la longueur de la fenêtre sélectionnée, la résolution temps-fréquence est fixée pour toute l'analyse. Un signal peut contenir à la fois des composantes tonales à variation lente (nécessitant une bonne résolution fréquentielle) et des transitoires rapides (nécessitant une bonne résolution temporelle). La STFT impose de choisir un compromis unique qui s'applique partout, ce qui peut être sous-optimal pour des signaux présentant des caractéristiques temps-fréquence diverses.

2. Principe d'incertitude

Le principe d'incertitude de Heisenberg-Gabor impose une limite inférieure stricte à la résolution conjointe temps-fréquence :

$$\Delta t \Delta f \geq \frac{1}{4\pi} \quad (\text{II.2})$$

Aucune fonction fenêtre, même conçue de manière optimale, ne peut dépasser cette limite. La fenêtre gaussienne atteint l'égalité (le produit minimum), c'est pourquoi elle est considérée comme optimale dans ce sens. Mais même à ce minimum théorique, il est impossible d'obtenir une résolution arbitrairement fine dans les deux domaines à la fois. [21].

II.2.2 L'analyse temps-échelle « Transformée en ondelette »

II.2.2.1 Définition et principe

La transformée en ondelettes continue (CWT, Continuous Wavelet Transform) est une méthode d'analyse qui, à l'instar de la transformée de Fourier, repose sur le produit scalaire afin d'évaluer la similarité entre un signal et une fonction d'analyse. Toutefois, contrairement à la

transformée de Fourier qui utilise des exponentielles complexes, la CWT emploie une ondelette mère ψ comme fonction d'analyse.

Le principe de la CWT consiste à comparer le signal à des versions translatées et dilatées de cette ondelette. La dilatation (ou mise à l'échelle) permet d'analyser différentes composantes fréquentielles, tandis que la translation permet de localiser ces composantes dans le temps. Ainsi, la CWT fournit une représentation du signal en fonction de deux variables: l'échelle et la position.

Cette représentation bidimensionnelle est généralement redondante. Lorsque l'ondelette est complexe, la CWT est une fonction complexe de l'échelle et de la position ; dans le cas d'un signal réel, elle peut être réelle. [22].

Pour une échelle $a > 0$ et une position b , la CWT est définie par :

$$W_{\{x\}(a,b)} = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi \left(\frac{t-b}{a} \right) dt \quad (\text{II.3})$$

- ψ : est la fonction d'ondelettes de base,
- b : la translation,
- a : le facteur de dilatation.
- $\frac{1}{\sqrt{a}}$: un coefficient utilisé pour avoir la même énergie dans chacune des ondelettes analysantes




Figure II .6 : Transformée en ondelette continue a l'échelle $a=5$ [23]

Si une composante spectrale du signal correspond à la valeur courante de a , le produit de l'ondelette par le signal, à l'emplacement où existe la composante spectrale, donne une valeur élevée. Si la composante spectrale correspondant à la valeur courante de a n'est pas présente dans le signal, la valeur de ce produit sera nulle ou très faible (Figure II .6). [23].

II.2.2.2 Limitations de la Transformé en ondelette

Un exemple de l'application d'une transformée en ondelettes continue (basée sur une ondelette de Morlet) à un train d'impulsions périodique est donné à la Figure II. 7

La CWT du signal témoigne d'une transition continue des échelles fines (hautes fréquences, où les impulsions sont « vues » en tant qu'individus) aux grandes échelles (basses fréquences, où la

périodicité se termine avec des raies spectrales). Il est à noter que l'axe des fréquences est affiché sur une échelle logarithmique [24].




Figure II. 7 : la CWT d'un train d'impulsions périodique [24]

II.2.3 La transformée Synchrosqueezing

II.2. 3.1 définition

La transformée Synchrosqueezing (SST) est une méthode avancée d'analyse temps-fréquence conçue pour améliorer la concentration de l'énergie des signaux non stationnaires. Son principe consiste à réaffecter les coefficients de la représentation temps-fréquence afin de produire une représentation plus précise et plus concentrée. Cette technique facilite l'identification des composantes fréquentielles du signal ainsi que l'extraction des informations caractéristiques associées à chaque mode. [25].

La SST est généralement construite à partir de la transformée de Fourier à court terme (STFT) Définie par :

$$Fs(t, w) = \int_{-\infty}^{+\infty} x(\tau) g^*(\tau - t) e^{-jw(\tau - t)} d\tau \quad (II.4)$$

(t, w) : Représentent respectivement le temps et la fréquence, $*$: est le symbole conjugué.

La SST offre une excellente concentration de l'énergie et une meilleure localisation des composantes fréquentielles grâce à la réduction de l'étalement spectral et à la mise en évidence des lignes de crête. Cependant, elle présente certaines limites, notamment un coût de calcul élevé, une sensibilité au bruit lorsque le SNR est faible, ainsi qu'une dépendance au choix des paramètres de la STFT, en particulier la fenêtre d'analyse.

II.3 Les représentations temps-fréquence quadratique

Les distributions temps-fréquence linéaires présentent des limitations et des inconvénients qui les rendent inadaptées à certains types de signaux et d'applications. Par exemple, elles peuvent ne pas être en mesure de représenter avec précision les signaux dont le contenu spectral est non stationnaire ou variable dans le temps, ou souffrir d'une faible résolution en raison du compromis inhérent entre la résolution temporelle et la résolution fréquentielle. [26].

Pour surmonter ces problèmes, une classe de distributions temps-fréquence appelées distributions temps-fréquence quadratiques (QTFD) a été développée.

II.3.1 Spectrogramme

II.3.1.1 Définition

Le spectrogramme est le module au carré de la TFCT. Il fait partie des représentations temps-fréquence bilinéaires [27].

$$S_x(t, f) = \left| \int_{-\infty}^{\infty} x(u) \cdot h^*(u - t) \cdot e^{-2\pi j f u} du \right|^2 \quad (\text{II.5})$$

Ceci définit qui est une distribution à valeurs- réelles et Non- négatives. Étant donné que la fenêtre h de la STFT est supposée avoir une énergie unitaire [28]. Le spectrogramme satisfait la propriété de distribution d'énergie globale :

$$\iint_{-\infty}^{+\infty} S_x(t, v) dt dv = E_x \quad (\text{II.6})$$

Ainsi, nous pouvons interpréter le spectrogramme comme une mesure de l'énergie du signal contenu dans le domaine temps-fréquence centré sur le point (t, v) et dont la forme est indépendante de cette localisation [28].

II.3.1.2 Propriétés

Cette représentation comporte de nombreux intérêts à savoir : [29].

- ❖ C'est une distribution d'énergie (à condition que $\int |h(t)|^2 dt = 1$). (II.7)
- ❖ Elle est invariante par translation en temps et en fréquence.
- ❖ Ne comporte pas de termes d'interférence ce qui permet une meilleure lisibilité.
- ❖ Son implémentation est simple (module au carré de la TFCT discrète) [29].

II.3.1.3 Résolution temps fréquence

Une bonne résolution en temps nécessite une court durée de la fenêtre d'analyse, d'autre part une bonne résolution en fréquence nécessite une bande étroite c'est-à-dire une longue durée de $w(t)$ (la fenêtre d'analyse de STFT). Mais malheureusement on ne peut pas garantir une bonne résolution en temps et en fréquence simultanément. Donc on doit assurer un compromis entre résolution en temps et fréquence. Cette limitation résulte l'inégalité de *Heisenberg-Gabor*. [30].

1. Parfaite résolution en temps :

Cela implique une fenêtre $w(t)$ comme une impulsion de Dirac

$$w(t) = \delta(t) \rightarrow F_x(t, f; h) = x(t)e^{-2\pi jft} \quad (\text{II.8})$$

Le STFT a une parfaite résolution en temps mais n'a aucune résolution en fréquence. Prenant un signal 'x' avec une modulation en fréquence linéaire et une modulation d'amplitude gaussienne ainsi une fenêtre d'analyse exprime une impulsion de Dirac. La Figure II.8 représente le résultat de la RTF du signal $x(t)$ en utilisant une impulsion de Dirac. Le signal est parfaitement localisé en temps mais nulle en fréquence [30].

2. Parfaite résolution en fréquence :

Prenant le même signal 'x' mais avec une fenêtre d'analyse $w(t)$ constante, avec cette résolution le STFT se réduit à une transformée de Fourier simple avec aucune résolution en temps mais résolution parfaite en fréquence. La Figure II.9 représente la RTF du signal $x(t)$ avec une fenêtre d'analyse constante [30].




Figure II.8 : Une résolution parfaite avec STFT
En temps avec impulsion de Dirac [30]




Figure II.9 : Une résolution parfaite
En fréquence [30]

II.3.2 Distribution de Wigner-Ville

II.3.2.1 Définition et principe

La distribution de Wigner-Ville a été développée en mécanique quantique en 1932 par E. P. Wigner et introduite en traitement du signal par J. Ville en 1948 [Vil48] [31].

$$WVD_x(t, f) = \int_{-\infty}^{\infty} x(t + \frac{\tau}{2}) \cdot x^*(t - \frac{\tau}{2}) \cdot e^{-2\pi j \cdot f \cdot \tau} d\tau \quad (\text{II.9})$$

Avec :

- $WVD_x(t, f)$: la fonction de Wigner
- t : variable de temps
- $t + \frac{\tau}{2}$: le temps moyen
- $\tau = t_1 - t_2$: le décalage dans le temps
- x^* : indique le conjugué de $x(t)$.

L'argument en faveur de cette représentation est sa résolution simultanée en temps et en fréquence, qui ne connaît pas les limitations du spectrogramme. De plus, la distribution de Wigner-Ville possède des propriétés théoriques qui la placent au cœur de la problématique des représentations non paramétriques bilinéaires.

On peut la considérer comme une distribution d'énergie dans la plan-temps fréquence, puisque la sommation de la distribution en temps permet de retrouver la densité d'énergie fréquentielle. Cependant, cette interprétation énergétique est discutable à cause de l'existence des termes d'interférences importants entre les différentes composantes fréquentielles avec la RTF ainsi la présence de valeurs négatives locales sur la distribution. Ces propriétés peu souhaitables et peuvent être atténuées par l'utilisation du signal analytique à la place du signal réel, ainsi par un lissage. [30].

La DWV est caractérisé par des valeurs réel, conservation temporelle et fréquentielle et satisfaire les propriétés marginale.

II.4 Les distributions basées sur les noyaux

Les distributions basées sur les noyaux sont des représentations temps-fréquence qui utilisent une fonction noyau afin de transformer et d'adapter la distribution du signal aux besoins de l'analyse. Cette fonction permet d'améliorer la lisibilité de la représentation en mettant en évidence les composantes significatives du signal tout en atténuant les effets indésirables. Le choix du noyau influence directement les caractéristiques de la distribution obtenue, notamment la concentration de l'énergie et la résolution temps-fréquence. Ces distributions sont largement utilisées pour l'analyse des signaux non stationnaires en raison de leur flexibilité et de leur capacité à fournir une représentation adaptée à différentes applications [32].

II.4.1 Le noyau CB Polynomial (PCB)

Le noyau à support compact PCB (Polynomial Cheriet-Belouchrani kernel) est également Dérivé du gaussien mais suit une forme polynomiale [33].

Il peut être exprimé dans le domaine temps-retard comme suit :

$$Gp(t, \tau) = \begin{cases} \frac{\gamma+1}{\pi\lambda^{2\gamma+2}} (\lambda^2 - (t^2 + \tau^2))^\gamma & \text{si } (t^2 + \tau^2) < \lambda^2 \\ 0 & \text{ailleurs} \end{cases} \quad (\text{II. 10})$$

Où λ est un paramètre prédéterminé et le contrôleur de bande passante γ est considéré comme un entier positif de sorte que le noyau résultant à une forme polynomiale. Cette caractéristique est très intéressante de point de vue paramétrage et optimisation de la représentation associée.

Pour estimer la spécificité de ce noyau, il est utile de rappeler une propriété très importante pour l'analyse temps-fréquence. Comme illustré à la Figure II.10, Les auto termes de la fonction d'ambiguïté se situent au niveau de l'origine dans le plan retard-Doppler, tandis que les termes croisés se trouvent loin de l'origine

Par conséquent, le PCB dans le domaine retard-Doppler (Figure II.11), obtenu par la transformée de Fourier inverse de Gp par rapport à t (Voir Eq(II. 10)) agit comme un filtre passe-bas bidimensionnel à fenêtre auto centré autour de l'origine, ce qui conduit à une suppression plus importante des interférences tout en préservant au mieux les termes du signal original [34].




Figure II. 10 : Localisation des autos termes du signal et des termes d'interférence : (a) le domaine temps-fréquence (la distribution de Wigner-Ville (WVD)) et (b) le domaine du décalage Doppler (la fonction d'ambiguïté) [34]




Figure II. 11 : Profil KCS bidimensionnel pour une bande passante fixe ($\gamma= 2,5, L = 64$). (a) Plan du décalage temporel et (b) plan du délai Doppler (domaine d'ambiguïté) [34]

II.4.2 Distribution B modifiée et distribution B modifiée Elargie

a. Distribution B modifiée

Une DTF récemment introduite, qui s'est avérée très efficace dans la suppression des termes croisés, est la distribution B modifiée (MBD). Pour améliorer la résolution temporelle, la distribution B a été modifiée en rendant le facteur dépendant du retard exactement constant [35].

La distribution B modifiée (MBD) résultante se caractérise par un noyau indépendant du retard appartenant ainsi à la famille "lag-independant (LI) kernels" et est défini dans le plan temps-retard Comme suit :

$$G_{MB}(t, \tau) = gb(t) = \int_{-\infty}^{+\infty} \frac{\cosh^{2\beta}(t)}{\cosh^{2\beta}(\xi)} d\xi \quad (\text{II.11})$$

Où β est un paramètre réel positif qui contrôle le degré de lissage, et sa valeur est comprise entre zéro et l'unité. Le dénominateur, quant à lui, est pour la normalisation. [35].

La distribution B modifiée (MBD) ne possède aucun paramètre permettant d'adapter une direction spécifique de la fenêtre de lissage dans le domaine temps-fréquence (TF). Par conséquent, cette méthode ne peut pas atteindre une concentration d'énergie optimale pour les signaux modulés en fréquence qui suivent une certaine direction dans le plan TF.[35].

b. Distribution B modifiée Elargie

La distribution élargie B (*Extended Modified B Distribution EMBD*) est une amélioration du MBD obtenu en ajoutant une fonction de noyau identique dans le sens du retard dans le domaine d'ambiguïté. En conséquence, l'EMBD peut mieux caractériser les signaux dont les composantes apparaissent le long des directions temporelles ou fréquentielle ou ailleurs, en accordant deux paramètres, chacun contrôlant la forme et la taille du noyau dans un axe. Le filtre du noyau dans le plan temps- retard est défini comme suit : [35].

$$G_{EMB}(t, \tau) = gb(t) = \int_{-\infty}^{+\infty} \frac{\cosh^{-2\beta}(t) e^{2j\pi\tau \cdot t}}{\cosh^{-2\beta}(t) dt} \cos^{-2\alpha}(\tau) \quad (\text{II.12})$$

L'EMBD utilise deux paramètres de contrôle, α et β , permettant d'ajuster séparément le niveau de lissage selon les axes temps et fréquence. Cette flexibilité offre un meilleur contrôle du compromis entre l'atténuation des termes croisés et la préservation de la résolution temps-fréquence. Grâce à cette propriété, l'EMBD améliore la concentration de l'énergie dans le plan temps-fréquence tout en réduisant efficacement les interférences indésirables. Où une bonne précision temporelle et fréquentielle est requise [35].

II.5 Conclusion

La détection et la classification des mouvements humains par radar reposent sur l'analyse des signatures micro-Doppler, caractérisées par leur nature fortement non stationnaire. Dans ce cadre, ce chapitre a présenté les principaux outils d'analyse temps-fréquence, en distinguant les approches linéaires, telles que la transformée de Fourier à court terme (STFT) et la transformée en ondelettes (CWT), des approches quadratiques, notamment le spectrogramme et la distribution de Wigner-Ville.

Par ailleurs, des méthodes plus avancées ont été abordées, telles que la transformation de Synchrosqueezing, permettant une meilleure concentration de l'énergie des composantes fréquentielles dans le plan temps-fréquence, ce qui améliore la lisibilité de la représentation. Des approches adaptatives basées sur la décomposition du signal, comme l'EMBD, ont également été introduites, offrant une représentation plus adaptée aux signaux non stationnaires et multi-composants. En complément, la distribution basée sur les noyaux à support compact (PCBD) a été présentée comme une alternative dans le cadre des représentations temps-fréquence.

Cependant, malgré leur utilisation répandue, certaines méthodes présentent des limites liées à la représentation de l'énergie dans le domaine temps-fréquence.

Ainsi, ces différentes représentations constituent un cadre pertinent pour la classification des mouvements humains. Une étude comparative sera menée en s'appuyant sur le spectrogramme, l'EMBD, la PCBD et la transformation de Synchrosqueezing, afin d'extraire des caractéristiques discriminantes des signatures micro-Doppler et d'identifier la représentation la plus appropriée pour alimenter efficacement les algorithmes de classification.

Chapitre III

Classification des signaux micro-doppler

Chapitre III

III.1 Introduction

L'analyse des mouvements humains à partir des signaux radar micro-Doppler est un domaine de recherche en plein développement, avec des applications importantes en sécurité et en surveillance intelligente. Ces signaux sont caractérisés par une forte non-stationnarité, ce qui rend les méthodes classiques de traitement du signal insuffisantes pour leur analyse.

Pour répondre à cette limitation, les représentations temps-fréquence constituent une solution adaptée, car elles permettent d'analyser simultanément l'évolution temporelle et fréquentielle du signal. Grâce à ces techniques, il est possible de mieux représenter la dynamique des signaux micro-Doppler et d'en extraire des informations discriminantes.

Ces informations sont essentielles pour distinguer différentes classes d'activités humaines, telles que « Walking » et « Running », en mettant en évidence les signatures caractéristiques propres à chaque mouvement.

Dans ce travail, l'analyse temps-fréquence constitue une étape essentielle et décisive dans le processus global de traitement du signal. Elle prépare directement la phase suivante, qui consiste en l'apprentissage automatique et la classification des activités humaines, objectif principal de cette étude

La suite de ce travail sera donc consacrée à l'exploitation des représentations temps-fréquence obtenues, afin de développer et d'évaluer des méthodes de classification.

III.2 Description de la base de données

Les principales caractéristiques techniques du radar Doppler de surveillance terrestre ainsi que la description de la base de données utilisée dans cette étude sont ci-dessous

Radar	Mesure	Données
 Type de radar Radar pulsé Doppler de surveillance terrestre	 Résolution en portée 150 m	 Types de cibles Personnes seules et groupes de personnes
 Fréquence 16.8 GHz	 Résolution en azimuth 5°	 Type de mouvements « Rampant-marche-cours » Walking ,Running,Crawling
 Puissance moyenne 5 MW	 Résolution en élévation 7,5°	 Directions des mouvements « Éloignement ou Rapprochement du radar » Go-away , Toward
 Largeur d'impulsion 15 µs	 Fréquence d'échantillonnage 4 kHz	
	 Durée d'enregistrement ≥ 20 secondes	

Tableau III.1 : Paramètres du système radar et organisation des données [36]

Cette organisation permet une meilleure structuration des classes utilisées pour l'apprentissage et L'évaluation des modèles de classification des mouvements humains [36].




Figure III.1 : Organisation de la base donnée utilisée [36]

Après la présentation de la base de données, ce projet de fin d'études s'inscrit dans le cadre de l'analyse des signaux non stationnaires issus des mouvements humains. Pour cela, une famille spécifique de représentations temps-fréquence quadratiques a été adoptée, Permettant une description conjointe de l'évolution temporelle et fréquentielle du signal.

Parmi les méthodes utilisées, on retrouve tout d'abord le Spectrogramme basé sur la transformation de Fourier à court terme (STFT). Le spectrogramme représente une distribution temps-fréquence quadratique, obtenue directement à partir de la transformée de Fourier à court terme (STFT). Il appartient à la classe des distributions temps-fréquence covariantes par translation en temps et en fréquence. Toutefois, sa résolution est limitée par un compromis entre la résolution temporelle et la résolution fréquentielle. [37]

Afin d'améliorer la qualité de représentation, des méthodes quadratiques plus avancées basées sur des noyaux ont été introduites. Parmi elles, la Polynomial Cherié-Belouchrani Distribution (PCBD) une représentation à haute résolution dans le temps et la fréquence, car il repose sur un noyau à support compact (compact support), ce qui le rend facile à optimiser. Il fonctionne également comme un filtre passe-bas bidimensionnel centré autour de l'origine, et cela permet une élimination plus importante des interférences tout en préservant mieux les composantes du signal original. [38]

Par la suite, la distribution B modifiée élargie (EMBD) Par conséquent, l'amélioration de cette distribution permet à l'EMBD d'améliorer la caractérisation des signaux dont les composantes s'étendent le long de la direction du temps ou de la fréquence. La fonction EMBD fournit également un bon compromis entre les exigences d'amélioration de la précision et la réduction des interférences entre les bornes. Ces méthodes constituent des représentations plus précises et mieux adaptées à l'analyse des signaux complexes non stationnaires. [39]

Enfin, la méthode de Synchrosqueezing (SST) est utilisée comme technique avancée conçue pour améliorer la concentration de l'énergie dans les signaux non stationnaires, elle vise également à

fournir une représentation concentrée des signaux multi composantes dans le plan temps-fréquence, Ainsi qu'une méthode d'analyse permettant de séparer les différents motifs. [40]

Ces différentes méthodes seront appliquées aux données afin de comparer leurs performances et d'évaluer leur capacité à représenter efficacement les mouvements humains.




Figure III.2 : Analyse temps-fréquence par la méthode Spectrogramme des signatures micro-Doppler
(A) Une personne qui marche et (B) une personne qui court




Figure III.3 : Analyse temps-fréquence par la méthode PCBD des signatures micro-Doppler
(A) Une personne qui marche et (B) une personne qui court




Figure III.4 : Analyse temps-fréquence par la méthode EMBD des signatures micro-Doppler
(A) Une personne qui marche et (B) une personne qui court




Figure III.5 : Analyse temps-fréquence par la méthode SST des signatures micro-Doppler
(A) Une personne qui marche et (B) une personne qui court

Les figures ci-dessus (figures III.2 III.3 III.4 III.5) présentent les diagrammes temps-fréquence générés par les méthodes Spectrogramme, PCBD, EMBD et SST, illustrant les signatures micro-Doppler d'une personne marchant (A) et d'une personne courant (B). La fréquence Doppler est affichée sur l'axe vertical, tandis que le temps est représenté sur l'axe horizontal, et l'amplitude du signal réfléchi est indiquée par des couleurs, du bleu pour les faibles intensités au rouge pour les intensités les plus élevées selon la méthode utilisée. On observe pour la marche (A) une concentration significative de l'énergie autour de 200 Hz, caractéristique des mouvements réguliers et de faible amplitude du torse. En comparaison, la signature micro-Doppler d'une personne qui court (B) présente une fréquence dominante plus élevée, autour de 600 Hz. Cette élévation de fréquence reflète l'augmentation de la vitesse et de l'amplitude des mouvements corporels associée à la course par rapport à la marche.

Le constat visuel des diagrammes temps-fréquence permet d'observer des différences notables entre les quatre méthodes.

La méthode Spectrogramme (Figure III.2) offre la représentation la plus riche et la plus contrastée, où la marche (A) se caractérise par une bande fine et régulière, tandis que la course (B) se distingue par l'apparition d'oscillations supplémentaires autour de la bande principale, traduisant les mouvements rapides des membres et facilitant l'extraction de caractéristiques discriminantes.

La méthode PCBD (Figure III.3) présente un contraste légèrement moins marqué que le Spectrogramme, mais malgré cela, elle reste une représentation claire et pertinente, avec une bande similaire et régulière pour la marche (A), alors que la course (B) montre des oscillations verticales nettes et répétées tout au long du signal, reflétant la dynamique des mouvements des bras et des jambes.

Les méthodes EMBD (Figure III.4) et SST (Figure III.5) quant à elles, produisent des représentations plus fines mais moins explicite, où la marche (A) se limite à une fine bande de points concentrés, tandis que la course (B) montre une bande plus large accompagnée de pics verticaux périodiques, traduisant l'augmentation de l'intensité et de la fréquence des mouvements, bien que l'information reste globalement moins contrastée par rapport au fond.

Les figures (III.6 III.7 III.8 III.9) présentent les diagrammes temps-fréquence pour un groupe de personnes marchant (A) et courant (B), selon les quatre méthodes d'analyse.




Figure III.6 : Analyse temps-fréquence par la méthode Spectrogramme des signatures micro-Doppler (A) Un groupe de personnes marchant et (B) un groupe de personnes courant




Figure III.7 : Analyse temps-fréquence par la méthode PCBD des signatures micro-Doppler (A) Un groupe de personnes marchant et (B) un groupe de personnes courant




Figure III.8 : Analyse temps-fréquence par la méthode EMBD des signatures micro-Doppler
 (A) Un groupe de personnes marchant et (B) un groupe de personnes courant




Figure III.9 : Analyse temps-fréquence par la méthode SST des signatures micro-Doppler
 (A) Un groupe de personnes marchant et (B) un groupe de personnes courant

Pour la méthode Spectrogramme (Figure III.6), la marche en groupe (A) montre une fine bande rouge concentrée en bas, tandis que la course en groupe (B) présente une bande plus large, plus dense et plus étendue verticalement, traduisant la superposition des signatures de plusieurs personnes en mouvement rapide.

La méthode PCBD (Figure III.7) suit une tendance similaire mais présente une représentation légèrement plus floue que le Spectrogramme, mais reste cohérente, avec un contraste légèrement plus marqué pour la course (B), où la bande d'énergie devient nettement plus épaisse et continue par rapport à la marche (A)

Pour la méthode EMBD (Figure III.8), la marche (A) se caractérise par une fine ligne concentrée en bas, tandis que la course (B) montre une bande fine, nette et continue légèrement

décalée vers des fréquences plus élevées. La méthode SST (Figure III.9) suit une tendance similaire pour la marche (A), mais présente pour la course (B) une bande plus large accompagnée de davantage de points dispersés autour de la bande principale, traduisant une représentation légèrement plus bruitée comparée à celle obtenue avec EMBD.

Bien que l'analyse visuelle des diagrammes temps-fréquence permette de dégager certaines tendances entre les différentes méthodes, elle reste insuffisante pour déterminer avec précision la méthode la plus performante pour la classification des activités humaines. Il est donc nécessaire de recourir à des techniques d'apprentissage profond, capables d'extraire automatiquement des caractéristiques discriminantes complexes à partir de ces représentations, afin d'évaluer objectivement et quantitativement les performances de chaque méthode d'analyse. et ainsi de classifier les mouvements humains selon individuelle et en groupe.

III.3 Apprentissage profond

L'apprentissage profond (deep learning) est un sous-domaine de l'intelligence artificielle qui utilise des réseaux neuronaux artificiels composés de nombreuses couches pour résoudre des tâches complexes. L'apprentissage profond permet des progrès importants et rapides dans les domaines de l'analyse du signal sonore ou visuel, notamment de la reconnaissance faciale, de la reconnaissance vocale, de la vision par ordinateur, du traitement automatisé du langage.

Les réseaux de neurones en apprentissage profond comprennent notamment les réseaux convolutifs (CNN) pour le traitement des images, ou les réseaux récurrents (RNN) pour les données temporelles, ainsi que les réseaux LSTM (Long Short-Term Memory), ce qui permet de traiter et résoudre une grande variété de problèmes [41].

III.3.1 Réseaux de Neurones Convolutifs (CNN)

Les CNN sont des réseaux de neurones spécialisés dans le traitement d'images. Leur architecture comprend deux blocs :

1. **Extracteur de features** : par convolutions successives, chaque couche applique des noyaux de filtrage, produit des *featuremaps* normalisées (activation) et redimensionnées, réitérant le processus. Les dernières *featuremaps* sont aplaties en un vecteur, sortie du bloc.
2. **Classifieur** : ce vecteur subit combinaisons linéaires et activations pour produire un vecteur final dont chaque composante i est la probabilité d'appartenance à la classe i .

L'apprentissage suit la rétropropagation du gradient (minimisation de l'entropie croisée), les paramètres appris étant notamment les caractéristiques des images. Les couches typiques d'un CNN sont : convolution, pooling, ReLU et fully-connected. [42].




Figure III. 10 : Les couches d'un réseau de neurones convolutif (CNN) [63]

- **Les couches des réseaux de neneurones convolutifs**

Une architecture CNN est une construction mathématique qui se compose généralement de trois types de couches distinctes la convolution, l'activation (ou ReLU) et le pooling et fully connected.

La couche de convolution La couche de convolution applique un ensemble de filtres convolutifs aux images en entrée pour utilise une réduction de dimension sur le signal d'entrée [43]

favorise un apprentissage plus rapide et plus efficace en remplaçant les valeurs négatives par des zéros et en conservant les valeurs positives. Ce procédé est parfois appelé activation, car seules les caractéristiques activées sont transmises à la couche suivante [43].




Figure III.11: La couche de convolution [64]

La couche de pooling simplifie la sortie en réalisant un sous-échantillonnage non linéaire, ce qui permet de réduire le nombre de paramètres que le réseau doit apprendre [43].




Figure III.12 : Couche de Pooling [64]

Couches entièrement connectées (fully connected) elles permettent de prendre des décisions finales, comme classer une image dans une catégorie. Les opérations sont répétées sur des dizaines ou des centaines de couches, chaque couche apprenant à identifier différentes caractéristiques [8].




Figure III.13: Couches entièrement connectées [64]

III.3.2 Les LSTM (Long Short-Term Memory)

Les réseaux LSTM sont une variation des réseaux de neurones récurrents (RNN). Ils ont été proposés par Jürgen Schmidhuber et son équipe au début des années 1990. Alors que les RNN classiques ont des difficultés à traiter les dépendances à long terme en raison du problème du « vanishing gradient », les LSTM ont été spécialement conçus pour surmonter ce problème [44].

Les réseaux LSTM introduisent une nouvelle unité appelée cellule mémoire, qui permet au réseau de stocker et d'accéder à des informations sur une longue période. La figure III.14 suivante illustre cela :




Figure III.14 : Composant d'une cellule LSTM [9]

La cellule mémoire d'un réseau LSTM est composée de trois portes : la porte d'entrée, la porte de sortie et la porte d'oubli. Ces portes contrôlent le flux d'informations dans la cellule mémoire, permettant de décider quelles informations doivent être conservées ou oubliées. Cela donne aux LSTM la capacité de retenir des informations importantes sur de longues séquences et d'ignorer les informations moins pertinentes.

h_t Représente l'état caché dans les RNN, tandis que dans les LSTM on ajoute l'état c_t . Ainsi, h_t correspond à la mémoire à court terme et c_t à la mémoire à long terme [44].

La porte d'oubli (2) permet au LSTM de supprimer les informations obsolètes de la cellule mémoire. Elle utilise à la fois l'entrée actuelle et l'état précédent pour générer un vecteur d'activation qui détermine quelles informations doivent être oubliées. Cela se traduit également par une opération mathématique effectuée entre ce deuxième vecteur d'activation et l'état précédent c_{t-1} . C'est à partir des deux opérations précédentes sur c_{t-1} que l'on obtient l'état actuel c_t [45].




Figure III.15: Porte d'oubli [45]

La porte d'entrée (1) détermine quelles informations doivent être mises à jour dans la cellule mémoire. Elle prend en compte l'entrée actuelle x_t ainsi que l'état précédent de la cellule mémoire h_{t-1} et génère un vecteur d'activation qui représente les informations à ajouter à la cellule c_{t-1} . Cet ajout d'informations se traduit par une opération mathématique effectuée entre ce vecteur d'activation et l'état précédent c_{t-1} [45].

Une fois que les valeurs de la porte d'entrée i_t et de l'état de cellule candidat $\tilde{C}_t$ ont été calculées, l'état de cellule c_t est mis à jour en combinant ces informations




Figure III.16: Porte d'entrée [45]

La porte de sortie (3) détermine la sortie du LSTM à un instant donné. Elle utilise l'entrée actuelle x_t et l'état actuel de la cellule mémoire c_t pour générer un vecteur d'activation qui représente la sortie du LSTM. C'est ainsi que l'on obtient h_t [45].




Figure III.17 : Porte sortie [45]

Fonction d'activation

« Sigmoid » donne un résultat entre 0 et 1 « Tanh » donne un résultat entre -1 et 1 [11].




Figure III.18 : Fonction d'activation Sigmoid (a) et (b) Tangente hyperbolique [46]

Dans le cadre de ce projet, une gamme de modèles dédiés à la classification des mouvements humains a été implémentée aux fins d'une évaluation comparative, visant à déterminer la stratégie d'analyse du signal la plus pertinente. La démarche adoptée s'organise selon deux approches distinctes : la première mobilise uniquement des réseaux de neurones convolutifs préalablement entraînés, la seconde associe à ces derniers une couche récurrente de type LSTM.

III.3.3 Modèles utilisés pour la première approche

a. InceptionV3

L'architecture du réseau InceptionV3 est construite progressivement à partir de plusieurs techniques visant à améliorer la précision tout en [47] réduisant le coût computationnel : (Voir figure III.20)

1. Convolution factorisées (Voir figure III.19)
2. Petites convolutions
3. Convolution asymétriques Classifier.
4. Classifieur auxiliaire
5. Réduction de la taille de la grille




Figure III.19 : Convolution factorisées [47]




Figure III.20 : Architecture d'InceptionV3 [48]

b. ResNet101V2

ResNet101v2 est une version étendue de l'architecture originale ResNet introduite par Kaiming He. Residual Network (ResNet101V2) est un type de CNN qui excelle dans l'entraînement de réseaux très profonds, en atténuant le problème de disparition du gradient grâce à l'utilisation de blocs résiduels. ResNet101v2 est une évolution qui affine la conception originale, en améliorant son efficacité et ses performances [48].

L'innovation clé derrière ResNet101v2 réside dans son utilisation de blocs résiduels. Ces blocs contiennent des connexions de raccourci, permettant au réseau de sauter des couches pendant la propagation avant et arrière. Cette conception aide à prévenir le problème de disparition du gradient, permettant ainsi l'entraînement réussi de réseaux extrêmement profonds.

De plus, ResNet101v2 intègre la Batch Normalization et des fonctions d'activation avancées, contribuant à une convergence plus rapide pendant l'entraînement. Cette conception minutieuse permet à ResNet101v2 de capturer des caractéristiques complexes dans les images, ce qui en fait un choix robuste pour les tâches de classification d'images (Voir Figure III.21) [48].




Figure III.21: Architecture de ResNet101v2 [49]

Le Tableau IV.4 présente un résumé comparatif des modèles exploités, permettant ainsi de confronter la complexité structurelle et la profondeur de chaque réseau mis en œuvre pour notre tâche de classification.

Modèle	Nombre de couches	Architecture	Détails
InceptionV3	48	Modules Inception (convolutions asymétriques et parallèles) + Pooling moyen global + FC	<ul style="list-style-type: none"> 5 x Conv (3x3 et 7x7 avec réduction de dimension) + 2 x Pooling 3 x Modules Inception (A) : Convolutions parallèles (1x1, 3x3, 5x5) 5 x Modules Inception (B) : Convolutions asymétriques factorisées (1x7 puis 7x1) 2 x Modules Inception (C) : Convolutions étendues en parallèle Pooling moyen global FC (1000 neurones)
ResNet-101V2	101	Blocs convolutifs résiduels (V2 avec pré-activation) + Pooling moyen global + FC	<ul style="list-style-type: none"> Conv (64 filtres, 7x7) + Pooling Bloc 1 : 3 conv résiduels (256 filtres) Bloc 2 : 4 conv résiduels (512 filtres) Bloc 3 : 23 conv résiduels (1024 filtres) Bloc 4 : 3 conv résiduels (2048 filtres) Batch Normalization + ReLU (Pré-activation) Pooling moyen global FC (1000 neurones)

Tableau III.2 : Résumé des architectures des modèles utilisés [49] [50]

III.3.4 Modèles utilisés pour la deuxième approche

Alors que les modèles CNN (InceptionV3 et ResNet101V2) excellent dans l'extraction de caractéristiques spatiales, ils ne prennent pas en compte de manière native la dépendance temporelle entre les trames (frames) successives. Les mouvements humains (comme la marche ou la course) étant des phénomènes dynamiques continus, une approche hybride s'impose. Dans cette configuration, les réseaux CNN pré-entraînés sont exploités exclusivement comme des extracteurs de caractéristiques (Feature Extractors) afin de générer des vecteurs descripteurs de haut niveau. Ensuite, ces vecteurs sont injectés séquentiellement dans la couche LSTM, qui prend en charge la modélisation des variations temporelles et des chronologies du signal pour réaliser la classification finale et affiner la distinction entre les différentes classes de mouvements. Nous concentrons sur la classification de




Figure III.22 : Architecture des modèles hybrides

Nous nous concentrons sur la classification de plusieurs types de mouvements humains individuels et en groupe de personnes. Les activités étudiées comprennent principalement la marche, la course. Les signaux micro-Doppler issus de ces mouvements sont transformés en images temps-fréquence à l'aide de différentes méthodes d'analyse, notamment le spectrogramme, la distribution PCBD, la distribution EMBD ainsi que la SST. Le nombre total d'images obtenues pour chaque classe apparaît au niveau de la Figure III.22. Les images générées par ces représentations temps-fréquence sont ensuite utilisées comme entrées d'un modèle hybride.

Cependant, en raison du grand nombre de paramètres des réseaux profonds, leur entraînement direct sur des ensembles de données de petite taille reste difficile et peut conduire à un problème de surapprentissage «overfitting». Afin de palier à ce problème et d'améliorer la capacité de généralisation du modèle, une technique d'augmentation des données (Data Augmentation) a été appliquée.

III.4 Augmentation des données

Le manque de données disponibles représente un défi important. Les modèles d'intelligence artificielle nécessitent généralement un grand volume de données pour apprendre efficacement, mais les ensembles de données restent parfois limités. Cette insuffisance peut entraîner un surapprentissage, ce qui réduit les performances du modèle lors des tests [51]

Pour remédier à ce problème, la technique d'augmentation des données est utilisée. Elle consiste à créer de nouvelles données à partir des échantillons existants en appliquant différentes transformations. Cette approche permet d'augmenter la diversité des données d'entraînement, de limiter le surapprentissage et d'améliorer la précision ainsi que la capacité de généralisation des modèles (avant l'augmentation 344 image total et après 2064image) . L'augmentation des données est réalisée à l'aide de plusieurs transformations aléatoires, définies comme suit :

Technique	Description	Paramètres
L'augmentation des données	une taille fixe	224×224 (ResNet101V2) 299×299 (InceptionV3)
1- Rotation	Rotation de l'image	$[-7^\circ, +7^\circ]$
2- Flip Horizontal	Retournement horizontal	Flip Code=1
3- Flip Vertical	Retournement vertical	Flip Code=0
4- Crop	Recadrage Aléatoire	central_fraction = 0.85
5- Brightness	Augmentation de luminosité	max_delta = 0.2

Tableau III.3 : Les paramètres d'augmentation




Figure III.23 : Ensemble des images
Avant augmentation





Figure III.24 : Ensemble de images
Après augmentation

Le Tableau III.4 présente un exemple d'images issues de l'ensemble d'entraînement de cette base de Données avant et après augmentation.




Tableau III.4 : Exemples d'images avant et après augmentation des données.

III. 5 Description de la préparation expérimentale

Cette préparation expérimentale suit plusieurs étapes. L'ensemble de données initial, subit d'abord un découpage 80 % pour l'entraînement et les 20 % restants sont séparés équitablement en validation (10 %) et test (10 %). Cette séparation est effectuée avant toute augmentation afin de garantir l'intégrité de l'évaluation et d'éviter toute fuite de données. Dans un second temps, un processus d'augmentation personnalisé est appliqué uniquement sur l'ensemble d'entraînement, incluant des transformations de luminosité, de retournement horizontal et vertical, de rotation et de recadrage central, multipliant ainsi par six l'effectif. Les ensembles de validation et de test restent non augmentés afin de représenter fidèlement les conditions réelles de classification.

Les modèles sont déjà pré-entraînés sur ImageNet, une base de données contenant plus d'un million d'images. Grâce au transfert learning, On a adapté les modèles utilisés aux classes étudiées au niveau de notre application. La taille d'entrée de chaque modèle est 224×224 pixels pour ResNet101V2 et 299×299 pixels pour InceptionV3, avec 3 canaux de couleur (RGB), tandis que la taille du lot (batch size) est configurée à 16. De plus, nous avons activé l'entraînement des poids (class weights) pour résoudre le problème de déséquilibre de nos classes, permettant ainsi aux modèles d'apprendre des caractéristiques fines propres à notre domaine d'étude.




Figure III.25 : Architecture globale du système de classification des mouvements humains

Paramètre	Valeur	Les classes	Original	Entraînement	Val	Test
Nombre des époques	100	1Personne Marchant	99	79	10	10
Nombre d'itérations	104	1Personne Courant	71	57	7	7
Early Stopping	patience = 10	Group Marchant	124	99	12	13
ReduceLROnPlateau	factor = 0.3 patience = 5	Group Courant	50	40	5	5
Learning rate minimale	1e-8	Total	344	275	34	35
Couches entraînaibles	20 dernières					


Tableau III.5 : Paramètres d'entraînement
Des modèles

Tableau III.6 : Répartition des images par classe
Avant et Après découpage

Les classes	1Personne Courant	1Personne Marchant	Group Courant	Group Marchant	Total
Entraînement (×6 aug)	342	474	240	594	1650
Validation	7	10	5	12	34
Test	7	10	5	13	35
Total	356	494	250	619	1719
Class weight	1.21	0.87	1.72	0.69	Balanced

Tableau III.7 : Répartition des images par classe après augmentation

Pour les variantes ResNet101V2 et InceptionV3 sans LSTM, nous avons appliqué une couche GlobalAveragePooling2D directement sur les sorties des modèles pré-entraînés, le GlobalAveragePooling2D compresse les feature maps de dimension (None, 8, 8, 2048) pour inceptionV3 et (None, 7, 7, 2048) pour resNet101V2 en un vecteur fixe de dimension (None, 2048) en calculant la moyenne de chaque carte de caractéristiques. Cette réduction du nombre de paramètres permet d'éviter le surapprentissage (overfitting), tout en conservant les informations globales les plus discriminantes extraites par le modèle pré-entraîné. Le vecteur résultant est ensuite transmis à des couches Dense avec des couches de régularisation Dropout intercalées, avant la classification final 4 classes via une activation softmax.

**Figure III.26** : (A) Architecture pratique du InceptionV3 de sans LSTM et (B) Architecture pratique du ResNet101V2 sans LSTM

Modèle/ Architecture	Approche	Paramètres Totaux	Paramètres Entraînaibles	Paramètres Non- Entraînaibles
ResNet101V2	Spatiale	42 757 956	8 011 076	34 746 880
InceptionV3	Spatiale	21 934 180	2 066 756	19 867 424

Tableau III.8: Caractéristiques techniques des paramètres des modèles

Pour les variantes ResNet101V2-LSTM et InceptionV3-LSTM, nous avons substitué la couche de Pooling par une couche Reshape. En effet, au lieu de réduire brutalement les features maps en un seul vecteur via le Global Average Pooling, la couche Reshape transforme la sortie du modèle pré-entraîné de dimension (None, 8, 8, 2048) pour inceptionV3 et (None, 7, 7, 2048) pour resNet101V2 en une séquence temporelle de dimension (None, 8, 16384) pour inceptionV3 et (None, 7, 14336) pour ResNet101V2. Où chaque pas de temps représente une région spatiale de l'image. Cette transformation permet à la couche LSTM d'exploiter les dépendances spatiales complexes et les relations séquentielles présentes, en traitant chaque région comme un élément d'une séquence temporelle. Ainsi, le modèle ne se contente pas d'extraire des caractéristiques globales, Mais capture également la dynamique temporelle et spatiale avant la classification finale en 4 classes marche individuelle, course individuelle, marche en groupe et course en groupe.

Tous les modèles sont compilés avec l'optimiseur Adam (avec un taux d'apprentissage de $1e-4$) la perte de catégorie croisée catégorique éparse (sparse categorical crossentropy) et la précision (Accuracy) comme métrique principale. Des callbacks de sauvegarde sont définis pour enregistrer le meilleur modèle au cours des 100 époques d'entraînement.




Figure III.27 : (A) Architecture pratique de l'InceptionV3 avec LSTM et (B) Architecture pratique du ResNet101V2 avec LSTM

Modèle/ Architecture	Approche	Paramètres Totaux	Paramètres Entraînables	Paramètres Non- Entraînables
ResNet101V2-LSTM	Spatiale-Temporelle	50 086 468	15 339 588	34 746 880
InceptionV3-LSTM	Spatiale-Temporelle	30 311 268	10 443 844	19 867 424

Tableau III.9 : Caractéristiques techniques des paramètres des modèles Hybride

Cette caractérisation précise de la complexité des modèles constitue un indicateur fondamental pour interpréter les dynamiques de convergence, les temps de calcul ainsi que la robustesse face au surapprentissage (overfitting) il va présentés dans chapitre suivantes.

III.6 Evaluation des métriques

Notre problème de classification présente un déséquilibre entre les différentes classes, une situation fréquemment rencontrée dans le domaine de la reconnaissance des mouvements humains. Pour mesurer réellement la qualité du modèle, le choix des métriques est crucial. Par exemple, la métrique la plus utilisée dans le domaine de l'apprentissage automatique est « Accuracy ». Cependant, en raison du déséquilibre des classes, nous allons opter pour d'autres métriques plus adaptées afin de mieux évaluer la qualité de notre modèle [52].

❖ La matrice de confusion

La matrice de confusion est un outil permettant de résumer les performances d'un algorithme de classification. Il donne un résumé des prédictions correctes et incorrectes ventilées pour chaque catégorie. Le résumé est représenté sous forme de tableau. Quatre types de résultats sont possibles lors de l'évaluation des performances d'un modèle de classification.

- **VP (Vrai Positif)** : Quand on prédit correctement qu'une valeur réelle est vrai.
- **VN (Vrai Négatif)** : Quand on prédit correctement qu'une valeur réelle est faux.
- **FP (Faux positif)** : Quand on prédit positivement, mais que la réalité est négative.
- **FN (Faux négatif)** : Quand on prédit négativement, mais que la réalité est positive [52].

		Etiquettes observées	
		+1	-1
Etiquettes prédites	+1	a) Vrais Positifs (VP)	b) Faux Positifs (FP)
	-1	d) Faux Négatifs (FN)	c) Vrais Négatifs (VN)
Total par colonne :		P	N

Figure III.28 : La matrice de confusion [66]

❖ Exactitude (Accuracy)

Proportion de prédictions correctes sur le total des prédictions. Elle peut être trompeuse si les classes sont déséquilibrées [52].

$$(VP + VN)/(VP + VN + FP + FN) \quad (III.1)$$

❖ Précision (Precision)

Mesure la capacité à ne pas classer un échantillon négatif comme positif. Cruciale quand le coût des faux positifs est élevé [52].

$$VP/(VP + FP) \quad (III.2)$$

❖ **Rappel (Recall)**

Mesure la capacité à détecter tous les échantillons positifs. Cruciale quand le coût des faux négatifs est élevé [52].

$$VP/(VP + FN) \quad (III.3)$$

❖ **F1-Score**

Moyenne harmonique entre la précision et le rappel, offrant un équilibre entre les deux [52].

$$2 \times (Précision \times Rappel)/(Précision + Rappel) \quad (III.4)$$

III.7 Conclusion

Dans ce chapitre, nous avons présenté les différentes étapes méthodologiques adoptées pour la conception du système de classification des mouvements humains. Nous avons d'abord décrit la base de données utilisée ainsi que les techniques d'analyse temps-fréquence appliquées afin d'extraire des représentations pertinentes des signaux micro-Doppler.

Ensuite, deux approches de classification ont été étudiées. La première repose sur l'utilisation de modèles de réseaux de neurones convolutifs pré-entraînés, notamment InceptionV3 et ResNet101V2, permettant l'extraction automatique des caractéristiques spatiales à partir des spectrogrammes générés. La seconde approche combine ces architectures CNN avec le réseau LSTM afin d'exploiter simultanément les informations spatiales et temporelles des séquences analysées.

Par ailleurs, des techniques d'augmentation de données ont été appliquées pour enrichir l'ensemble d'apprentissage, améliorer la capacité de généralisation des modèles et réduire le risque de surapprentissage. Enfin, la préparation expérimentale ainsi que les différents paramètres utilisés durant l'entraînement ont été détaillés afin d'assurer une évaluation fiable des performances des modèles proposés.

Ce chapitre constitue ainsi la base expérimentale de notre travail. Les résultats obtenus ainsi que leur analyse et leur discussion seront présentés dans le chapitre suivant.

Chapitre IV

Outils de simulation et discussion des résultats

Chapitre IV

IV.1 Introduction

Dans ce chapitre, nous présentons les résultats expérimentaux obtenus dans le cadre de la classification des mouvements humains à partir des signatures micro-Doppler. L'objectif principal de cette étude est d'évaluer l'influence des différentes méthodes d'analyse temps-fréquence utilisées sur les performances du système de reconnaissance.

Les résultats obtenus à partir des différentes représentations temps-fréquence seront analysés et comparés afin de déterminer la méthode la plus efficace pour l'extraction des caractéristiques des mouvements humains. Les performances des modèles utilisés seront également étudiées à travers plusieurs métriques d'évaluation et outils d'analyse expérimentale.

IV.2 L'environnement de travail et les outils utilisés

IV.2.1 Matériels

Le matériel utilisé est représenté dans le tableau suivant :

Composant	Caractéristiques du Système
Pc	Toshiba
Processeur	AMD E-350 Processor @ 1.60 GHz
Mémoire RAM	4,00 Go
Système d'exploitation	Windows (64 bits, processeur x64)

Tableau IV.1 : Caractéristiques du matériel utilisé pour le calcul physique

L'entraînement de réseaux de neurones profonds complexes (tels que InceptionV3 et ResNet101V2, seuls ou combinés avec des couches LSTM) requiert des capacités de calcul massives et une mémoire vidéo dédiée (GPU). Notre configuration locale étant limitée pour ce type de traitement intensif, nous avons migré l'exécution de nos scripts de calcul sur la plateforme Google Colab. Cela nous a permis de bénéficier gratuitement d'un accélérateur graphique GPU (Graphics Processing Unit) puissant, optimisant ainsi le temps d'apprentissage de nos 4 architectures.

- ✓ **Google Colab** : également connu sous le nom de « Colaboratory » ou Colab, est une plateforme offerte gratuitement par Google qui permet d'écrire et d'exécuter du code Python via un navigateur web. Fondé sur Jupyter Notebook, il est principalement utilisé dans le domaine de la formation et de la recherche en apprentissage automatique [56] (Figure IV.1).

IV.2.2 Langage de programmation

- ✓ **Python** : C'est le langage de programmation principal adopté dans ce projet. Le choix de Python se justifie par sa flexibilité, sa puissance de calcul et surtout par son écosystème exceptionnel dédié à l'Intelligence Artificielle et au traitement de données. Grâce à la richesse de ses bibliothèques spécialisées, Python nous a permis de centraliser tout notre flux de travail : depuis le chargement des images issues de nos 4 méthodes de traitement radar jusqu'à l'implémentation, l'entraînement et l'évaluation de nos 4 architectures de Deep Learning [53] (Figure IV.2).

**Figure IV.1** : Google Colab Logo [67]**Figure IV.2** : Python Logo [53]

IV.2.3 Bibliothèques utilisées

❖ TensorFlow

Est une bibliothèque open-source d'apprentissage automatique et profond développée par Google. Elle est hautement optimisée pour l'utilisation des ressources matérielles (CPU/GPU/TPU). Dans ce travail, TensorFlow sert de moteur principal (Backend) pour exécuter les calculs massifs Requis par notre architecture [53] (Figure IV.3).

**Figure IV.3** : TensorFlow Logo [53]

❖ OpenCV (cv2)

Elle est dédiée au prétraitement et au chargement Les images. Elle permet d'harmoniser les dimensions spatiales de ces représentations avant de les injecter dans les extracteurs de caractéristiques d'InceptionV3 ou ResNet101V (Figure IV.4).

**Figure IV.4:** OpenCV [68]

❖ Keras

Est une API de réseau de neurones écrite en langage Python capable de s'exécuter sur TensorFlow. Keras a été utilisée comme l'interface principale pour orchestrer nos 4 architectures. Elle nous a permis de charger InceptionV3 et ResNet101V2, de concevoir la transition spatio-temporelle via les couches Reshape et LSTM pour nos 4 méthodes de signaux, et d'optimiser l'entraînement [54] (Figure IV.5).

**Figure IV.5:** Keras Logo [54]

❖ NumPy

Cette bibliothèque est indispensable pour structurer l'entrée de nos modèles. Elle permet de convertir les fichiers images de nos 4 méthodes (Spectrogramme, SST, PCBD, EMBD) en matrices numériques (tableaux de pixels), assurant ainsi la normalisation des données et la compatibilité de leurs dimensions avec les exigences des architectures [55] (Figure IV.6).



Figure IV.6: Keras Logo [55]

❖ Scikit-learn (Sklearn)

Elle intervient de manière cruciale à deux niveaux :

1. Pour segmenter nos bases de données de manière stratifiée afin de garantir que les phases de train, validation et test contiennent la même proportion d'échantillons pour chaque méthode de traitement
2. Pour calculer les poids inverses et équilibrer la fonction de perte (*Loss Function*). C'est cet outil qui résout le problème du déséquilibre numérique entre nos 4 Classes. Assurant ainsi une comparaison équitable entre les performances des 4 classes (Figure IV.7).



Figure IV.7: Keras Logo [69]

❖ Matplotlib et Seaborn

Ces bibliothèques ont été utilisées pour tracer et superposer les courbes d'apprentissage (Précision/Perte) de nos 4 modèles à travers les 4 représentations du signal. Elles nous ont également permis de générer les matrices de confusion correspondantes afin d'analyser la capacité de chaque méthode à discriminer les mouvements des individus et des groupes [53] (Figure IV.8).



Figure IV.8: Matplotlib et Seaborn Logo [53]

IV.3 Résultats expérimentaux et évaluation

IV.3.1 Résultats obtenus pour la première Classification « Sans LSTM »

Modèle/ Méthodes		Spectrogramme	PCBD	EMBD	SST
InceptionV3	Exactitude	97.143%	97.143%	94.286%	91.429%
	Précision	96.88%	96.88%	95.24%	91.41%
	Recall	97.50%	95.00%	94.29%	92.01%
	F1_score	97.18%	96.51%	94.98%	91.42%
	Weighted F1_score	97.16%	97.08%	94.31%	91.45%
	Unweighted F1_score	97.19%	95.93%	95.64%	91.38%
	MCC	96.15%	96.13%	92.53%	88.22%
ResNet101V2	Exactitude	100%	97.143%	94.286	94.286%
	Précision	100%	96.88%	93.56%	94.55%
	Recall	100%	95.00%	94.51%	94.29%
	F1_score	100%	96.51%	93.965	94.31%
	Weighted F1_score	100%	97.08%	94.32%	94.20%
	Unweighted F1_score	100%	95.93%	93.61%	94.42%
	MCC	100%	96.13%	92.32%	92.13%

Tableau IV.2 : Performances obtenues pour les modèles InceptionV3 et ResNet101V2 des quatre méthodes d'analyse temps fréquence

Modèle/ Temps		Spectrogramme	PCBD	EMBD	SST
InceptionV3	Temps entraînement Totale	93 min	102 min	89 min	112 min
	Temps Inférence/image	0.171 sec	0.400 sec	0.400sec	0.800 sec
ResNet101V2	Temps entraînement Totale	106 min	121 min	166 min	120 min
	Temps Inférence/image	0.571 sec	0.543 sec	0.571 sec	0.857 sec

Tableau IV.3 : Temps d'entraînement total et Temps d'Inférence de chaque modèle

Le tableau IV.3 montre qu'InceptionV3 sur la méthode EMBD présente le temps d'entraînement le plus court avec 89 min, tandis que la méthode Spectrogramme affiche le temps d'inférence le plus rapide avec 0.171 sec/image. ResNet101V2 est globalement plus lent, avec un temps d'entraînement maximal de 166 minutes sur la méthode EMBD.

a. Le modèle InceptionV3




Figure IV.9 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode Spectrogramme Du modèle InceptionV3




Figure IV.10 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode PCBD Du modèle InceptionV3




Figure IV.11 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode EMBD Du modèle InceptionV3




Figure IV.12 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode SST Du modèle InceptionV3

Les courbes d'apprentissage du modèle InceptionV3 appliqué aux quatre méthodes d'analyse montrent globalement une convergence stable et progressive.

Figure IV.9 Pour la méthode **Spectrogramme**, la précision d'entraînement se stabilise rapidement autour de la 7^{ème} époque et une validation stabilisée de 97% avec une perte (Loss) qui diminue régulièrement sans oscillations.

Figure IV.10 Pour la méthode **PCBD**, la convergence est légèrement plus lente, avec une précision d'entraînement atteignant 100% vers la 12^{ème} époque et une validation convergeant vers 100% dès la 3^{ème} époque.

Figure IV.11 Pour la méthode **EMBD**, la précision d'entraînement atteint 100% vers la 12^{ème} époque avec une validation stabilisée autour de 97% dès la 6^{ème} époque, avec une perte (Loss) qui diminue de manière régulière et sans perturbations notables.

Figure IV.12 Enfin, pour la méthode **SST**, la précision d'entraînement atteint 100% en fin d'entraînement et la validation converge vers 97%, bien qu'elle présente quelques fluctuations en cours d'entraînement.

Dans l'ensemble, InceptionV3 démontre une bonne capacité de généralisation sur les quatre méthodes, avec des performances remarquables notamment sur les méthodes Spectrogramme et PCBD.

b. Le modèle ResNet101V2




Figure IV.13 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode Spectrogramme Du modèle ResNet101V2




Figure IV.14 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode PCBD Du modèle ResNet101V2




Figure IV.15 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode EMBD Du modèle ResNet101V2




Figure IV.16 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode SST Du modèle ResNet101V2

Les courbes d'apprentissage du modèle ResNet101V2 montrent une convergence rapide pour l'ensemble des quatre méthodes.


Figure IV.13, Pour la méthode **Spectrogramme** la précision d'entraînement atteint 100% dès la 2ème époque avec une validation autour de 97% et 100% dès la 6ème époque Puis il est revenu à 97%. Tandis que la perte (Loss) de validation présente des fluctuations importantes avec un pic atteignant 0.30 vers la 5ème époque.

Figure IV.14 Pour la méthode **PCBD**, la précision d'entraînement atteint 100% vers la 3ème époque, mais la validation présente des fluctuations marquées et la perte de validation affiche des oscillations avec un pic atteignant 0.38. Toutefois, l'instabilité observée sur la courbe de perte (Loss) de validation probablement due à la grande profondeur de son architecture à 101 couches résiduelles.


Figure IV.15 Pour la méthode **EMBD**, les deux courbes de précision convergente progressivement sur un nombre d'époques, la précision d'entraînement atteint 100% vers la 9ème époque, avec une perte (Loss) qui diminue régulièrement et de manière stable pour les deux courbes, sans oscillations notables.

Figure IV.16 Pour la méthode **SST** la précision d'entraînement atteint 100% en fin d'entraînement, tandis que la validation se stabilise autour de 95% avec des fluctuations, et la perte (Loss) de validation présente des oscillations importantes tout au long de l'entraînement.


Globalement, ResNet101V2 affiche de bonnes capacités d'apprentissage sur l'ensemble des quatre méthodes, avec un comportement particulièrement notable sur la méthode Spectrogramme.




(A) InceptionV3



(B) ResNet101V2


Figure IV.17 : Matrice de Confusion pour la méthode Spectrogramme

(C) InceptionV3




(D) ResNet101V2


Figure IV.18 : Matrice de Confusion Pour la méthode PCBD




(E) InceptionV3



(F) ResNet101V2

Figure IV.19 : Matrice de Confusion pour la méthode EMBD

(G) InceptionV3



(H) ResNet101V2

Figure IV.20 : Matrice de Confusion pour la méthode SST

Figure IV.17, Pour la méthode **Spectrogramme** ResNet101V2 affiche une classification parfaite sans aucune erreur, tandis qu'InceptionV3 présente une seule erreur de classification sur la classe 1 Personne marchant classés comme dans 1 Personne Courant

Figure IV.18 Pour la méthode **PCBD** les deux modèles affichent des performances similaires avec une seule erreur chacun sur la classe Groupe de Person Courant comme 1 Personne Courant.

Figure IV.19 Pour la méthode **EMBD** les deux modèles présentent un nombre d'erreurs similaire, principalement sur la classe Groupe de Person marchant 2 erreurs classés comme 1 Personne Marchant pour InceptionV3. Et pour ResNet101V2 1 erreurs classés comme InceptionV3 et l'autre dans 1 Personne Courant classés comme groupe de Person Courant.

Figure IV.20 Pour la méthode **SST** InceptionV3 présente 3 erreurs de classification, avec des confusions entre les classes 1 Personne Courant, dans 1 Personne Marchant, groupe de Person Marchant Tandis que ResNet101V2 affiche seulement 2 erreurs, limitées aux confusions entre les groups de Person Courant et group de Person Marchant.

L'analyse comparative des deux modèles InceptionV3 et ResNet101V2 sur les méthodes d'analyse « Spectrogramme, PCBD, et SST » montre que ResNet101V2 affiche globalement de meilleures performances de classification et surpasse InceptionV3. Et Il est important de noter que pour la méthode « EMBD », InceptionV3 affiche des performances légèrement supérieures à ResNet101V2 sur la majorité des métriques, constituant ainsi la seule exception où InceptionV3 surpasse ResNet101V2.

IV.3.2 Discussion

Dans cette étude, Les résultats obtenus montrent que le choix de la méthode d'analyse influence significativement les performances de classification. En comparant les deux modèles sur l'ensemble des méthodes, la méthode Spectrogramme se révèle la plus performante, avec 100% pour ResNet101V2 et 97.14% pour InceptionV3. La méthode PCBD arrive en deuxième position avec 97.14% pour les deux modèles. La méthode EMBD se place en troisième position avec des performances proches pour les deux modèles autour de 94.28%. Enfin, la méthode SST affiche les résultats les plus faibles, avec 94.28% pour ResNet101V2 et 91.43% pour InceptionV3. Ces résultats confirment que la représentation spectrale des signaux radar constitue la méthode d'analyse la plus adaptée à la reconnaissance d'activités humaines, permettant d'extraire des caractéristiques temporelles et fréquentielles riches et discriminantes.

IV.3.3 Résultats obtenus pour la deuxième Classification « Avec LSTM »

Modèle/ Méthodes		Spectrogramme	PCBD	EMBD	SST
InceptionV3 + LSTM	Exactitude	100%	97.143%	94.286	94.286%
	Précision	100%	96.88%	95.83%	95.09%
	Recall	100%	95.00%	96.15%	90.00%
	F1_score	100%	96.51%	94.98%	92.44%
	Weighted F1_score	100%	97.08%	94.31%	93.72%
	Unweighted F1_score	100%	95.93%	95.64%	91.16%
	MCC	100%	96.13%	92.53%	92.30%
ResNet101V2 + LSTM	Exactitude	100%	94.286%	91.429%	94.286%
	Précision	100%	92.24%	91.67%	92.26%
	Recall	100%	90.00%	92..58%	93.93%
	F1_score	100%	92.96%	91.49%	93.59%
	Weighted F1_score	100%	93.73%	91.47%	94.34%
	Unweighted F1_score	100%	92.24%	91.45%	92.84%
	MCC	100%	92.32%	88.70%	92.21%

Tableau IV.4 : Présente les performances obtenues pour les modèles Hybride des quatre méthodes d'analyse temps fréquence

Modèle/ Temps		Spectrogramme	PCBD	EMBD	SST
InceptionV3 + LSTM	Temps entraînement Totale	86 min	202 min	149 min	133 min
	Temps Inférence/image	0.229 sec	0.286 sec	0.857 sec	0.343 sec
ResNet101V2 + LSTM	Temps entraînement Totale	286 min	174 min	230 min	159 min
	Temps Inférence/image	0.543 sec	0.371 sec	0.771 sec	0.686 sec

Tableau IV.5 : Le temps d'entraînement total et le temps Inférence de chaque modèle Hybride

Le tableau IV.5 montre que les modèles hybrides présentent des temps d'entraînement et d'inférence variables selon la méthode utilisée. InceptionV3+LSTM est globalement plus rapide, avec un minimum de 86 minutes (Spectrogramme) et un maximum de 202 minutes (PCBD). ResNet101V2+LSTM est plus lent, allant de 159 à 286 minutes. Le temps d'inférence varie entre 0.229 et 0.857 sec/image, confirmant leur applicabilité dans les systèmes de reconnaissance d'activité basés sur le radar.

a. Le modèle Hybride InceptionV3 + LSTM




Figure IV.21 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode Spectrogramme Du modèle InceptionV3+LSTM




Figure IV.22 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode PCBD Du modèle InceptionV3+LSTM




Figure IV.23 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode EMBD Du modèle InceptionV3+LSTM




Figure IV.24 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode SST Du modèle InceptionV3+LSTM

Figure IV.21 Pour la méthode **Spectrogramme**, la précision d'entraînement atteint 100% dès la 5ème époque, tandis que la validation se stabilise autour de 100% à partir de la même époque, Concernant la perte (Loss), les deux courbes diminuent rapidement et de manière régulière jusqu'à des valeurs proches de zéro, sans oscillations notables.

Figure IV.22 Pour la méthode **PCBD**, la convergence est plus lente, la précision d'entraînement progressant graduellement pour atteindre 100% dès la 10ème époque, tandis que la précision de validation présente des fluctuations importantes avant de se stabiliser autour de 95-100%. Concernant la perte (Loss), les deux courbes diminuent globalement vers des valeurs proches de zéro, bien que la perte de validation affiche un pic notable autour de la 7ème époque.

Figure IV.23 Pour la méthode **EMBD**, la précision d'entraînement converge et se stabilise vers 100% dès la 10ème époque, tandis que la précision de validation présente des fluctuations importantes, oscillant entre 90% et 100% tout au long de l'entraînement. Concernant la perte (Loss), la courbe d'entraînement diminue régulièrement vers des valeurs proches de zéro, alors que la perte de validation affiche des oscillations marquées avec plusieurs pics, notamment en fin d'entraînement.

Figure IV.24 Enfin, pour la méthode **SST**, la précision d'entraînement et de validation convergente rapidement vers 100% dès la 5ème époque, avec une perte (Loss) qui diminue régulièrement et de manière stable pour les deux courbes.

Le LSTM apporte une amélioration significative sur Spectrogramme et SST dans inceptionv3 seul, deux méthodes qui contiennent une forte composante temporelle/séquentielle (variations liées au mouvement humain dans le temps). Le LSTM exploite efficacement ces dépendances temporelles pour mieux distinguer les classes.

Pour PCBD et EMBD, les performances restent presque identiques, ce qui suggère que ces représentations sont déjà suffisamment discriminantes sans information temporelle additionnelle, le modèle CNN seul capture déjà l'essentiel de l'information utile, et le LSTM n'apporte ni gain ni perte significative.

b. Le modèle Hybride ResNet101V2+ LSTM




Figure IV.25 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode Spectrogramme Du modèle ResNet101V2+LSTM




Figure IV.26 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode PCBD Du modèle ResNet101V2+LSTM




Figure IV.27 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode EMBD Du modèle ResNet101V2+LSTM




Figure IV.28 : Courbe d'exactitude et de perte d'entraînement et de validation en fonction du nombre d'époque pour La Méthode SST Du modèle ResNet101V2+LSTM

Figure IV.25 Pour la méthode **Spectrogramme**, la précision d'entraînement converge rapidement vers 100% dès la 5ème époque, tandis que la précision de validation se stabilise autour de 97% dès le début de l'entraînement. Concernant la perte, la courbe d'entraînement diminue rapidement vers des valeurs proches de zéro, tandis que la perte de validation se stabilise autour de 0.30 avec une légère tendance à l'augmentation en fin d'entraînement,

Figure IV.26 Pour la méthode **PCBD**, la précision d'entraînement converge rapidement vers 100% dès la 5ème époque, tandis que la précision de validation se stabilise autour de 94%. Concernant la perte (Loss), la courbe d'entraînement diminue rapidement vers des valeurs proches de zéro, tandis que la perte de validation se stabilise autour de 0.20 avec une légère tendance à l'augmentation en fin d'entraînement,

Figure IV.27 Pour la méthode **EMBD**, la précision d'entraînement converge rapidement vers 100% dès la 8ème époque, tandis que la précision de validation présente des fluctuations importantes, oscillant entre 80% et 100% tout au long de l'entraînement. Concernant la perte, la courbe d'entraînement diminue rapidement et reste proche de zéro, alors que la perte (Loss) de validation présente un pic important atteignant environ 1.0 autour de la 12ème époque, traduisant une instabilité ponctuelle du modèle face aux données de validation.

Figure IV.28 Pour la méthode **SST**, la précision d'entraînement converge rapidement vers 100% dès la 5ème époque, tandis que la précision de validation se stabilise autour de 97% avec quelques légères fluctuations. Concernant la perte (Loss), la courbe d'entraînement diminue rapidement vers des valeurs proches de zéro, tandis que la perte de validation présente des oscillations modérées tout au long de l'entraînement, sans pic majeur.

Pour la méthode PCBD et EMBD, l'ajout du LSTM entraîne une légère baisse de l'exactitude correspondant à une erreur de classification supplémentaire sur le test set. Cela suggère que les caractéristiques spatiales extraites par ResNet101V2 sont déjà suffisamment discriminantes pour cette méthode, et que la complexité additionnelle introduite par le LSTM n'apporte pas de gain, voire induit un léger surapprentissage sur ce petit ensemble de données. et limite la capacité de généralisation du Modèle. Pour les méthodes Spectrogramme et SST, les performances restent quant à elles globalement stables. Suggérant que le LSTM n'a ni d'impact positif ni négatif significatif sur ces méthodes pour ce modèle. À l'inverse, InceptionV3 (architecture moins profonde) bénéficie davantage du LSTM au (Spectrogramme et SST) car il a moins de capacité intrinsèque à capturer ces dépendances seul.







Figure IV.29 : Matrice de Confusion Pour la méthode de Spectrogramme




(C) InceptionV3+LSTM



(D) ResNet101V2+LSTM

Figure IV.30: Matrice de Confusion Pour la méthode de PCBD

(E) InceptionV3+LSTM



(F) ResNet101V2+LSTM

Figure IV.31 : Matrice de Confusion Pour la méthode d'EMBD




Figure IV.32 : Matrice de Confusion Pour la méthode de SST

L'analyse des matrices de confusion des modèles avec LSTM confirme les tendances observées précédemment.

Figure IV.29 Pour la méthode **Spectrogramme** les deux modèles affichent une classification parfaite sans aucune erreur.

Figure IV.30 Pour la méthode **PCBD**, InceptionV3+LSTM présente une seule erreur de classification, avec un exemple de la classe Groupe de Person Courant classé comme 1 Person Courant, tandis que ResNet101V2+LSTM affiche deux erreurs sur cette même classe, l'une classée comme 1 Person Courant et l'autre comme 1 Person Marchant, confirmant la légère baisse de performance observée pour ce modèle.

Figure IV.29 Pour la méthode **EMBD** InceptionV3+LSTM commet deux erreurs sur la classe Group de Person Marchant tandis que ResNet101V2+LSTM en cumule trois, réparties entre les classes 1 Person Courant et Groupe de Person Marchant.

Figure IV.29 Enfin, pour la méthode **SST** les deux modèles affichent un nombre d'erreurs similaire, soit deux erreurs chacun, principalement sur les classes liées au groupe et à la marche/course individuelle.

IV.3.4 Discussion

L'ensemble des résultats obtenus permet de dégager plusieurs constats. Tout d'abord, la méthode Spectrogramme se révèle être la méthode d'analyse la plus performante, atteignant 100% d'exactitude avec ResNet101V2 (avec et sans LSTM) ainsi qu'avec InceptionV3+LSTM, confirmant que la représentation spectrale et temporelle des signaux capture efficacement les caractéristiques discriminantes nécessaires à la reconnaissance d'activités humaines. La méthode PCBD conserve sa deuxième position, comme c'était le cas sans LSTM. En revanche, le classement des deux dernières méthodes s'inverse avec l'ajout du LSTM : la méthode SST passe en troisième position, grâce au gain

significatif apporté par le LSTM exploitant ses dépendances temporelles, tandis que la méthode EMBD, initialement troisième sans LSTM, se retrouve désormais en quatrième position.

Concernant l'apport du LSTM, son effet diffère selon l'architecture utilisée. Pour InceptionV3, dont la profondeur est plus modérée, le LSTM apporte un gain significatif sur les méthodes Spectrogramme et SST, en exploitant les dépendances temporelles que le modèle seul ne capture pas pleinement. En revanche, pour ResNet101V2, déjà très profond (101 couches résiduelles), l'ajout du LSTM n'apporte aucun bénéfice et entraîne même une légère baisse de performance sur PCBD et EMBD, probablement due à un surapprentissage causé par la complexité additionnelle sur un dataset de petite taille.

En termes de temps de calcul, InceptionV3 reste globalement plus rapide que ResNet101V2, aussi bien en entraînement qu'en inférence, ce qui en fait un choix intéressant pour des applications nécessitant un compromis entre performance et efficacité computationnelle.

En définitive, ResNet101V2 sans LSTM offre les meilleures performances globales, notamment sur les méthodes Spectrogramme, Cependant, InceptionV3+LSTM reste une alternative intéressante grâce à sa convergence stable, ses bonnes performances Surtout sur Spectrogramme et SST, et un temps de calcul plus faible.

IV.4 Conclusion

Dans ce chapitre, nous avons exploré différentes approches de classification des mouvements humains en exploitant les signatures micro-Doppler extraites de signaux radar. L'objectif principal était de comparer différentes méthodes d'analyse afin de déterminer la plus performante pour la reconnaissance de différents types de mouvements, tels que la marche et la course, ainsi que d'évaluer si l'ajout d'une couche LSTM apporte une amélioration significative aux modèles utilisés.

On a permis d'évaluer et de comparer les performances de deux architectures de transfert learning, InceptionV3 et ResNet101V2, avec et sans couche LSTM, appliquées à quatre méthodes de représentation des données radar (Spectrogramme, PCBD, EMBD et SST), pour la tâche de reconnaissance d'activités humaines.

Les résultats obtenus montrent que la méthode Spectrogramme constitue la représentation la plus performante, atteignant la plus haute exactitude avec ResNet101V2 (avec et sans LSTM) et avec InceptionV3+LSTM, confirmant la richesse de l'information temporelle et fréquentielle qu'elle contient.

L'analyse de l'apport du LSTM a révélé que son effet dépend de l'architecture de base : il améliore significativement les performances d'InceptionV3, alors qu'il a un effet neutre, voire légèrement négatif, sur ResNet101V2, dont la profondeur permet déjà une extraction efficace des caractéristiques sans recours à une modélisation temporelle additionnelle.

Enfin, ResNet101V2 sans LSTM s'est imposé comme le modèle offrant les meilleures performances globales, tandis qu'InceptionV3+LSTM représente une alternative compétitive avec un temps de calcul plus réduit. Ces résultats confirment l'efficacité du transfert learning combiné aux architectures profondes pour la classification d'activités humaines à partir de données radar, et ouvrent la voie à des perspectives d'amélioration telles que l'augmentation de la taille du dataset ou l'exploration d'autres architectures hybrides.

Conclusions Générale

Ce projet s'inscrit dans le domaine de l'analyse des signaux radar et vise à développer une approche efficace pour la reconnaissance des mouvements humains à partir des signatures micro-Doppler. Pour cela, il repose sur l'exploitation de représentations temps-fréquence capables de mettre en évidence les caractéristiques pertinentes des signaux radar, associées à des techniques d'apprentissage profond et de classification supervisée. L'objectif est d'identifier avec précision la classe à laquelle appartient chaque signal parmi les différentes catégories de mouvements étudiées.

L'étude a été réalisée à partir d'une base de données acquise par un radar de surveillance terrestre, contenant des signaux associés à quatre classes de mouvements humains : la marche et la course, effectuées soit par une personne seule, soit par un groupe de personnes « 1 Person Marchant, 1 Person Courant, Groupe de Person Marchant et Groupe de Person Courant ». Les déplacements des différentes parties du corps humain, notamment les bras, les jambes et le torse, génèrent des composantes micro-Doppler caractérisées par un comportement non stationnaire. L'analyse de ces signaux nécessite donc l'utilisation de représentations bidimensionnelles temps-fréquence, capables de décrire simultanément leur évolution temporelle et fréquentielle.

Plusieurs approches d'analyse temps-fréquence ont été étudiées, incluant les méthodes linéaires telles que la Transformée de Fourier à Court Terme (STFT) et la Transformée en Ondelettes, ainsi que des méthodes quadratiques telles que le Spectrogramme, la Distribution de Wigner-Ville, la PCBD et l'EMBD. Une attention particulière a également été portée à la méthode SST (Transformé de, Synchrosqueezing) reconnue pour sa capacité à améliorer la concentration temps-fréquence. Après une analyse comparative de ces différentes techniques, quatre représentations ont été retenues pour la phase expérimentale, à savoir le Spectrogramme, la PCBD, l'EMBD et la SST, en raison de leurs Aptitude à mettre en évidence les caractéristiques discriminantes des signaux micro-Doppler.

Les représentations temps-fréquence retenues ont été converties en images et utilisées comme données d'entrée pour des modèles de classification basés sur l'apprentissage par transfert (Transfer Learning). Dans un premier temps, les architectures CNN pré-entraînées InceptionV3 et ResNet101V2 ont été évaluées afin d'analyser leur capacité à extraire les caractéristiques pertinentes des signatures micro-Doppler. Par la suite, des architectures hybrides ont été proposées en associant ces réseaux convolutifs à une couche LSTM (Long Short-Term Memory), dans le but d'exploiter les dépendances temporelles. Cette démarche a permis d'étudier l'apport de l'association entre les réseaux convolutifs et les mécanismes de modélisation séquentielle sur les performances de classification des signaux micro-Doppler.

Pour permettre une évaluation objective, nous avons comparé les différentes combinaisons méthode/modèle selon plusieurs critères essentiels, à savoir : l'exactitude, les métriques de classification (Précision, Rappel, F1-score, MCC), le temps d'entraînement, ainsi que le temps d'inférence. Les résultats obtenus montrent que la méthode Spectrogramme associée au modèle ResNet101V2 se distingue comme la combinaison la plus performante, atteignant une exactitude de 100% avec une classification parfaite. Par ailleurs, l'ajout d'une couche LSTM a montré un apport bénéfique pour le modèle InceptionV3, tandis qu'il n'a apporté aucune amélioration pour ResNet101V2, dont la profondeur de l'architecture permet déjà une extraction efficace des caractéristiques sans recours à une modélisation temporelle additionnelle.

Globalement, ces résultats montrent que le choix de la méthode de représentation et de l'architecture du modèle joue un rôle déterminant dans la performance globale du système de classification

Recommandations et Perspectives pour les Travaux Futurs

Les perspectives d'amélioration et de prolongement de ce travail sont nombreuses et ouvrent la voie à plusieurs axes de recherche prometteurs. Dans des travaux futurs :

1. il serait pertinent d'explorer d'autres représentations temps-fréquence avancées, notamment celles basées sur des noyaux à support compact ou des approches adaptatives basées sur la décomposition modale, ainsi que des techniques récentes de réaffectation temps-fréquence permettant une meilleure concentration énergétique des signatures micro-Doppler.
2. Sur le plan de la classification, l'évaluation de modèles de deep learning plus récents, tels que EfficientNetV2, DenseNet201, Vision Transformer (ViT), Swin Transformer ou encore Xception, pourrait permettre d'améliorer les performances de reconnaissance tout en offrant une meilleure capacité de généralisation. Il serait également intéressant d'étudier des architectures hybrides combinant réseaux convolutifs, couches récurrentes GRU et mécanismes d'attention afin d'exploiter simultanément les informations spatiales et temporelles contenues dans les représentations temps-fréquence.
3. Une autre perspective consiste à mettre en œuvre des techniques de fusion de données (data fusion) en combinant plusieurs représentations temps-fréquence d'un même signal afin d'extraire des caractéristiques plus riches et plus discriminantes.
4. L'enrichissement de la base de données constitue également une étape importante. Celui-ci pourrait être réalisé par l'ajout de nouvelles activités humaines, telles que la marche avec charge, les changements de direction, les chutes, les mouvements stationnaires ou encore les déplacements de groupes de tailles variables. L'augmentation du nombre d'échantillons acquis dans différentes conditions environnementales (présence de bruit, variations météorologiques, distances d'observation variables ou obstacles partiels) permettrait d'évaluer plus rigoureusement la robustesse des modèles développés.
5. Enfin, il serait intéressant d'étendre cette étude à des scénarios plus complexes impliquant plusieurs cibles simultanées, des environnements réels de surveillance ou encore des systèmes radar de différentes bandes de fréquence. Une comparaison avec des approches basées sur l'analyse directe des signaux bruts, sans conversion préalable en images temps-fréquence, constituerait également une perspective pertinente pour évaluer l'apport réel des représentations utilisées dans ce travail.

Bibliographie

[1] Maradan, M. (2010). *Terminologie de l'effet Doppler : allemand-anglais-espagnol-espéranto-français*. Mémoire de master, Université de Genève.

https://www.eventoj.hu/steb/vortaroj/terminologio_de_la_doplera_efiko_retaversio1.pdf

[2] https://fr.wikipedia.org/wiki/Radar_Doppler

[3] INRS. (s.d.). Document ED 4350.

[file:///C:/Users/BMF%20INFO/Downloads/ed4350%20\(3\).pdf](file:///C:/Users/BMF%20INFO/Downloads/ed4350%20(3).pdf)

[4] Neipp, C., Hernandez, A., Rodes, J. J., Marquez, A., Belendez, T., & Belendez, A. (2003) *An analysis of the classical Doppler effect*. European Journal of Physics, 24(5), 497–505

<https://www.futura-sciences.com/sciences/definitions/physique-effet-doppler-2470/>

[5] Académie de Montpellier. (s. d.). *Fiche de synthèse n°10 : L'effet Doppler*. Terminale STL - Ondes.

https://spcl.acmontpellier.fr/moodle/pluginfile.php/24929/mod_resource/content/0/ONDES_FS10_Doppler.pdf

[6] Benabdelkader, S. (s. d.). *Chapitre 5 : Effet Doppler – Résumé* [Fichier PDF]. Université de Batna 2.

https://staff.univ-batna2.dz/sites/default/files/benabdelkader_souad/files/chapitre5_resumeeffetdoppler.pdf

[7] Tecnare. (s.d.). *L'effet Doppler comprendre sa science*

<https://www.tecnare.com/fr/article/leffet-doppler-comprendre-sa-science/>

[8] Les Sherpas, « L'effet Doppler : définition, formules et applications », *Physique*, 2023.

<https://sherpas.com/p/physique/effet-doppler.html>

[9] V, Chen. F, Li, S.-S. Ho, H. Wechsler « Micro-Doppler effect in radar: phenomenon, model, and simulation study » IEEE Transactions on Aerospace and Electronic Systems, January 2006

[10] A, Ghaleb « Analyse des micro-Doppler de cibles mobiles déformables en imagerie radar » Traitement du signal et de l'image Télécom Paris Tech, 2009.

[11] MathWorks. (s.d.). Introduction to micro-Doppler effects. MathWorks Radar Toolbox.

<https://www.mathworks.com/help/radar/ug/introduction-to-micro-doppler-effects.html>

[12] S. Hassan, X. Wang, S. Ishtiaq, N. Ullah, A. Mohammad, et A. Noorwali, « Human Activity Classification Based on Dual Micro-Motion Signatures Using Interferometric Radar », *Remote Sensing*, vol. 15, n° 7, p. 1752, mars 2023.

<https://www.mdpi.com/2072-4292/15/7/17523>

[13] Wikipédia.(s.d.).Échographie Doppler.

https://fr.wikipedia.org/wiki/%C3%89chographie_Doppler

[14] Boashash, B. (2016). Time–Frequency Signal Analysis. In Time-Frequency Signal Analysis and Processing: A Comprehensive Reference (2nd ed., pp. 1–3). Academic Press.

[15] Alliance Technologies. (s.d.). Micro Rain Radar 24GHz.

<https://www.alliance-technologies.net/micro-rain-radar-24ghz/>

[16] Thèses Algérie. (s.d.). Reconnaissance de l'activité humaine.

<https://theses-algerie.com/3976077300535928/memoire-de-master/universite-8-mai-1945---guelma/reconnaissance-de-l-activit%C3%A9-humaine-en-utilisant-les-wearable-sensors>

[17] M.-L. Bencheikh, « Détection radar dans le domaine temps-fréquence : Exploitation de la représentation réallouée », Mémoire de Magister, Option : Radar et Télédétection, École Nationale Polytechnique (ENP), Alger, 2000

[18] ScienceDirect, "Short-TimeFourierTransform(STFT)".

<https://www.sciencedirect.com/topics/engineering/short-time-fourier-transform>

[19] Boashash, B. (2016). Time–Frequency Signal Analysis. In Time-Frequency Signal Analysis and Processing: A Comprehensive Reference (2nd ed., pp. 1–3). Academic Press.

[20] Université Mouloud Mammeri de Tizi-Ouzou, Mémoire de fin d'études.
<https://dspace.ummo.dz/server/api/core/bitstreams/9ad9647c-c372-4960-88f5-2a8809389baa/content>

[21] Fiveable, "Short-Time Fourier Transform (STFT)".

<https://fiveable.me/advanced-signal-processing/unit-6/short-time-fourier-transform-stft/study-guide/DIDcR67AFZ58LkOX>

[22] MathWorks, "Continuous Wavelet Transform and Scale-Based Analysis".
<https://fr.mathworks.com/help/wavelet/gs/continuous-wavelet-transform-and-scale-based-analysis.html>

[23] Oussadane Kahina, Sekkai M., Mémoire de fin d'études.

[24] Seninete Sara, "Thèse Version Finale".

<https://fr.scribd.com/document/523104633/These-SENINETE-Sara-Version-Finale>

[25] M.-L. Bencheikh, « Détection radar dans le domaine temps-fréquence : exploitation de la

représentation réallouée », Thèse de Magister, École Nationale Polytechnique, Alger, 2000.

<https://hal.science/hal-00916088/document>

[26] V. Jurdana, « A multi-objective optimization procedure for locally adaptive time-frequency analysis with application in EEG signal processing », Doctoral dissertation, Faculty of Engineering, University of Rijeka, Rijeka, 2023

https://riteh.uniri.hr/media/filer_public/7f/14/7f14b33f-ca68-45d7-b743-3b992c31314f/doktorski_rad_vjurdana.pdf

[27] Hadj Ahmed, « Analyse temps-fréquence à haute résolution du signal HRV : Application à la télésurveillance des arythmies cardiaques », Thèse de Doctorat, Génie biomédical, Université Aboubakr Belkaïd, Tlemcen, 2022.

<https://dspace.univ-tlemcen.dz/items/c1384382-12ac-4532-af91-2f4e3dd89dff>

[28] F. Auger, P. Flandrin, P. Gonçalves et O. Lemoine, « Time-Frequency Toolbox: For Use with MATLAB », User's Guide, CNRS (France) / Rice University (USA), 1995-1996.

[29] R. Ajgou, « Techniques de détection de la période du pitch par les méthodes temps fréquence et temps échelle », Mémoire de Magister, Option : Communications, Université Mohamed Khider – Biskra, 2010.

<http://thesis.univ-biskra.dz/4421/1/AJGOU%20Riad.pdf>

[30] A. Kacha, « Analyse des signaux dans le domaine temps-fréquence », Thèse de Doctorat en Sciences, Filière : Electronique, Université Ferhat Abbas – Sétif (UFAS), Algérie.

http://dspace.univ-setif.dz:8888/jspui/bitstream/123456789/1435/1/th%C3%A8se_kacha.pdf

[31] O. F. Bouzouina et A. Hammou, « Détection des mouvements humains par l'analyse temps-fréquence des signaux micro-Doppler et l'intelligence artificielle », Mémoire de Master, Spécialité : Systèmes des Télécommunications, Université Abdelhamid Ibn Badis, Mostaganem, 2025

<https://e-biblio.univ-mosta.dz/items/c20c4b65-0ef1-42a1-9a77-77a7ed83c7c3>

[32] P. Flandrin, *Time-Frequency/Time-Scale Analysis*, Academic Press, 1999

[33] Seninete Sara, "Thèse Version Finale".

<https://fr.scribd.com/document/523104633/These-SENINETE-Sara-Version-Finale>

[34] "On the Use of High Resolution Time-Frequency Distribution Based on a Polynomial Compact Support Kernel for Fault Detection in a Two-Level Inverter".
https://www.academia.edu/48113020/On_the_Use_of_High_resolution_Time_frequency_Distribution_Based_on_a_Polynomial_Compact_Support_Kernel_for_Fault_Detection_in_a_Two_level_Inverter

[35]<https://dspace.univ-tlemcen.dz/bitstreams/75295eb6-a603-43be-a668-862a58a0d93f/download>

[36] The database of radar echoes from various targets (2010) [Online].

<https://mega.nz/file/L4Nzxa4K#sSes9SnbRVUUn59Z8bUtg782p685Lv69IVKVx1FzITw>

[37] Gabor, D. (1946). Theory of communication. Journal of the Institution of Electrical Engineers - Part III: Radio and Communication Engineering, 93(3), 429–457

[38] S. Seninete *et al.*, « On the Use of High-resolution Time-frequency Distribution Based on a Polynomial Compact Support Kernel for Fault Detection in a Two-level Inverter », *Periodica Polytechnica Electrical Engineering and Computer Science*, vol. 64, n° 4, 2020.

<https://pp.bme.hu/eecs/article/view/15469>

[39] Université Abdelhamid Ibn Badis de Mostaganem. Mémoire de Master.

<https://e-biblio.univ-mosta.dz/server/api/core/bitstreams/a32aefed-cbdb-403d-b755-93cfa943f8a6/content>

[40] Scientific Reports. « Article ».

<https://www.nature.com/articles/s41598-024-68216-x>

[41] Wikipédia. « Apprentissage profond ».

https://fr.wikipedia.org/wiki/Apprentissage_profond

[42] Université Kasdi Merbah Ouargla. Mémoire de Master.

https://dspace.univ-ouargla.dz/jspui/bitstream/123456789/28648/1/IATARIEN-Abderraouf_.pdf

[43] MathWorks. « Convolutional Neural Network (CNN) ».

<https://fr.mathworks.com/discovery/convolutional-neural-network.html>

[44] Liora. « Long Short-Term Memory (LSTM) : tout savoir ».

<https://liora.io/long-short-term-memory-tout-savoir>

[45] Université du Québec à Trois-Rivières. Mémoire.

<https://depot-e.uqtr.ca/id/eprint/11790/>

[46] Amiar, T., & Belkai, S. « Réalisation d'un IDS à base d'un réseau LSTM ». Mémoire de Master, Université Mouloud Mammeri, Tizi-Ouzou, 2026.

[47] NoCodingAI. « InceptionV3 ».

<https://medium.com/@nocodingai/inceptionv3-10e6f48e4553>

[48] DigitalOcean. « Popular Deep Learning Architectures: ResNet, InceptionV3 and SqueezeNet ».

<https://www.digitalocean.com/community/tutorials/popular-deep-learning-architectures-resnet-inceptionv3-squeezenet>

[49] Burak M. « Unveiling the Power of ResNet101V2 ».

<https://mtburakk.medium.com/unveiling-the-power-of-resnet101v2-a-deep-dive-into-image-classification-d1a10ad02f29>

[50] arXiv. Deep Residual Learning for Image Recognition.

<https://arxiv.org/pdf/1512.00567>

[51] Université Hassiba Benbouali de Chlef. Mémoire.

<https://dspace.univ-chlef.dz/server/api/core/bitstreams/5dfb4af3-02f3-4ec1-ba69-da1aae9fb5b1/content>

[52] Mon Shot Data. « Cheat Sheet ultime des métriques de performance en Machine Learning ».

<https://www.monshotdata.com/p/cheat-sheet-ultime-des-metriques-de-performance-en-machine-learning>

[53] Université Hassiba Benbouali de Chlef. Mémoire.

<https://dspace.univ-chlef.dz/items/a2c0108d-7779-4a29-a88c-a80d06abeb5c>

[54] Université Mohamed El Bachir El Ibrahimi de Bordj Bou Arreridj. Mémoire.

<https://dspace.univ-bba.dz/server/api/core/bitstreams/106e836d-82ef-46be-b34a-ecb440487ba1/content>

[55] Université Mohamed Khider Biskra. Mémoire.

http://archives.univ-biskra.dz/bitstream/123456789/18922/1/AMEUR_HMAIDA.pdf

[56] Université d'Aïn Témouchent. Mémoire.

<https://dspace.univ-temouchent.edu.dz/server/api/core/bitstreams/98d5946e-8981-40c5-9c27-95000b87c33f/content>

[57] Wikipédia. « Christian Doppler ».https://fr.wikipedia.org/wiki/Fichier:Christian_doppler.jpg

[58] Fine Art America. « Christoph Buys Ballot ».

<https://fineartamerica.com/featured/christoph-buys-ballot-universal-history-archiveuig.html>

[59] Adobe Stock. Radar Doppler.

<https://stock.adobe.com>

[60] Store norske leksikon. « Rødforskyvning ».

<https://snl.no/r%C3%B8dforskyvning>

[61] YouPhysics Education. « Effet Doppler »

<https://www.youphysics.education/fr/effet-doppler/>

[62] V, Chen. F, Li, S.-S. Ho, H. Wechsler « Micro-Doppler effect in radar: phenomenon, model, and simulation study » IEEE Transactions on Aerospace and Electronic Systems, January 2006

[63] VMV-Tech (Naver Blog). Analyse temps-fréquence utilisant la transformée de Fourier à court terme (STFT).

<https://m.blog.naver.com/vmv-tech/220936084562?recommendTrackingCode=2>

[64] VMV-Tech (Naver Blog). Window length = 3,3 s (comparaison entre une fenêtre longue et une fenêtre courte).

<https://m.blog.naver.com/PostView.nhn?isHttpsRedirect=true&blogId=vmv-tech&logNo=220941821088>

[65] MathWorks. « Convolutional Neural Network (CNN) ».

<https://fr.mathworks.com/discovery/convolutional-neural-network.html>

[66] ResearchGate. « Matrice de confusion d'un classifieur binaire ». https://www.researchgate.net/figure/Matrice-de-confusion-dun-classifieur-binaire-C-De-cette-matrice-de-confusion-on-peut_fig3_281658915

[67] Rofiahr. « MySkill Data Analysis Part 2: Python Using Google Colab ». Medium.

<https://medium.com/@rofiahr828/myskill-data-analysis-part-2-python-using-google-colab-349caa58862e>

[68] Wikipédia. « OpenCV Logo with text ».

https://fr.wikipedia.org/wiki/Fichier:OpenCV_Logo_with_text.png

[69] Wikipédia. « Scikit-learn ».

<https://fr.wikipedia.org/wiki/Scikit-learn>

