



وزارة التعليم العالي والبحث العلمي

MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET
DE LA RECHERCHE SCIENTIFIQUE

جامعة عبد الحميد بن باديس

Université Abdelhamid Ibn Badis de Mostaganem

كلية العلوم والتكنولوجيا

Faculté des Sciences et de la Technologie

DEPARTEMENT DE GENIE DES ELECTRONIQUE



MEMOIRE

Présenté pour obtenir le diplôme de

MASTER EN TELECOMMUNICATIONS

Spécialité : *Systemes des Télécommunications*

Par : Mlle BOUZOUINA Oujdene Fella

Mlle HAMMOU Amina

**Détection des mouvements humains par l'analyse temps-
fréquence des signaux micro-Doppler et l'intelligence artificielle**

Soutenu le **29/06/ 2025** devant le jury composé de :

Président :	M. Daoud Mohamed	MCA	UMAB
Examinatrice :	Mme BENCHELLAL Amel	MCB	UMAB
Encadreur :	M. ABED Mansour	MCA	UMAB
Co- Encadreur :	M. NAHI Ahmed	Doctorant	UMAB

Année universitaire : 2024/2025

Remerciements

Nous rendons grâce à Dieu Tout-Puissant de nous avoir accordé santé, force et persévérance tout au long de ces années, nous permettant ainsi de poursuivre et de terminer nos études, et de réaliser notre souhait de mener à bien ce projet de fin d'études.

Nous tenons à exprimer notre profonde gratitude à notre encadrant, Monsieur ABED Mansour, pour son soutien constant, sa disponibilité, ses conseils avisés, ses compétences scientifiques, ainsi que pour son soutien et sa bienveillance tout au long de ce travail.

Nous ne vous remercierons jamais comme il se doit.

Nous remercions également Monsieur NAHI Ahmed et Monsieur LARBI Arezki pour nous avoir guidés dans la réalisation de ce travail, notamment l'implémentation algorithmique des réseaux CNN étudiés.

Nos sincères remerciements à notre examinatrice et instructrice, Mme BENCHHELLAL Amel, pour ses conseils, sa confiance, sa patience et son aide précieuse.

Nous tenons à remercier Monsieur DAOUD Mohamed qui nous a fait l'honneur d'accepter d'examiner ce travail.

Nos plus sincères remerciements vont également à toute l'équipe pédagogique du Département de Génie Electrique de l'Université Abdelhamid Ibn Badis de Mostaganem, ainsi qu'à toutes les personnes qui, de près ou de loin, ont contribué à la réalisation de ce travail, particulièrement les membres du laboratoire de recherche Signaux et Systèmes (LSS) sous la direction de M. ABED Mansour.

Bouzouina Oujdene & Hammou Amina

Dédicaces

Je dédie ce travail à :

*Mes chers parents, pour leur amour inestimable, leur patience et leur soutien constant
tout au long de mon parcours,*

*À mes sœurs, Kaouter et Aya, pour leur affection, leurs encouragements et leur présence
rassurante,*

À mon mari, pour sa compréhension, son soutien quotidien et sa précieuse bienveillance,

À toute ma famille, pour leur aide sincère, leur gentillesse et leur présence à mes côtés,

*À mon binôme Hammou Amina pour son engagement, sa persévérance et la belle
complicité qui nous a portées tout au long de ce travail,*

À toutes les personnes qui m'ont aidée de près ou de loin dans ce travail.

Bouzouina Oujdene

Dédicaces

Je dédie ce travail aux personnes qui me sont les plus chères :

À ma très chère mère, raison de mon existence, pour tes sacrifices, ton soutien, ta générosité et ta tendresse. Tu as toujours été là près de moi pour me soutenir, m'encourager et me guider de tes précieux conseils,

À mon très cher père, l'épaule forte, source de sacrifice, pour ta tendresse, ton soutien, tes conseils et tes encouragements,

À mes très chers frères Abdelkader et Abderrahmane et mes chères sœurs Souhila et Ikram,

À toute la famille sans exception,

À mon binôme Oujdene et sa famille,

À tous ceux que j'aime et qui m'aiment.

Hammou Amina

Résumé

L'analyse des mouvements humains à l'aide de signatures micro-Doppler suscite un intérêt croissant, notamment pour les applications de surveillance, de biométrie et de sécurité civile et militaire. La plupart des études précédentes s'appuyaient sur des caméras vidéo et autres capteurs portables pour collecter des données sur l'activité humaine. Cependant, l'un des principaux inconvénients des systèmes basés sur la vision est leur limitation dans les environnements où la visibilité est réduite. En outre, compromettre la confidentialité peut nuire au bien-être des utilisateurs et à leur confiance dans les systèmes de santé en particulier. Par conséquent, la protection de la confidentialité des utilisateurs et de la sécurité des données est cruciale pour les applications de télésurveillance médicale et militaire. Les capteurs radar présentent l'avantage potentiel de capturer des données d'activité humaine tout en préservant la confidentialité de l'utilisateur. De ce point de vue, ce travail porte sur la détection et la classification des mouvements humains de marche et de course, qu'ils soient effectués par une ou plusieurs personnes, en exploitant l'analyse temps-fréquence des signaux micro-Doppler.

Tout d'abord, nous traitons les signaux radar en utilisant une analyse temps-fréquence de haute résolution. Parmi les méthodes existantes, une famille spécifique de distributions temps-fréquence quartiques est utilisée pour convertir les tracés TF des signaux étudiés en images d'entrée pour les classifieurs. Plus précisément, nous utilisons une représentation compacte à noyau polynomial appelée distribution polynomiale de Cheriet-Belouchrani (PCBD). Cette dernière sert à extraire des caractéristiques distinctives de différentes classes de mouvement humain. Ensuite, ces caractéristiques sont exploitées pour une classification automatique à l'aide d'algorithmes d'intelligence artificielle. Nous mettons en œuvre des méthodes d'apprentissage automatique (Machine Learning), notamment Support Vector Machine (SVM). De plus, nous intégrons des approches d'apprentissage profond (deep learning), telles que les réseaux de neurones convolutifs (CNNs) pour améliorer la robustesse et la précision de la classification. Les résultats obtenus confirment la robustesse des modèles CNN utilisés en combinaison avec l'analyse temps-fréquence réalisée par la PCBD, atteignant une précision de test parfaite de 100%.

Mots-clés : Analyse temps-fréquence, signaux micro-Doppler, classification, SVM, apprentissage automatique, apprentissage profond, reconnaissance d'activité humaine, CNNs.

Abstract

Human activity recognition (HAR) using micro-Doppler signatures is attracting growing interest, particularly for surveillance, biometrics, and civil and military security applications. Most previous studies have relied on video cameras and other wearable sensors to collect data on human activity. However, a major drawback of vision-based systems is their limitation in environments where visibility is reduced. Moreover, compromising privacy can negatively impact users' well-being and trust in healthcare systems in particular. Therefore, maintaining user privacy and data security is crucial for remote health monitoring and military applications. Radar sensors have the potential advantage of capturing human activity data while preserving the user's privacy. From this perspective, this work focuses on the detection and classification of human walking and running movements, whether performed by one person or group of persons, by exploiting time-frequency analysis of micro-Doppler signals.

First, we process the radar signals using high-resolution time-frequency analysis. Among the existing methods, a specific family of quadratic time-frequency distributions (QTFDs) is employed to convert the TF plots of the micro-Doppler signals into input images to the investigated classifiers. Specifically, we utilize a compact kernel representation called the Polynomial Cheriet-Belouchrani distribution (PCBD). The latter is used to extract distinctive characteristics of different classes of human movement. Then, these features are used for automatic classification using artificial intelligence algorithms. We implement machine learning methods, including Support Vector Machine (SVM). Additionally, we integrate deep learning approaches, such as convolutional neural networks (CNNs) to improve classification robustness and accuracy. The results obtained confirm the robustness of the CNN models used in combination with the time-frequency analysis performed by the PCBD, achieving a perfect test accuracy of 100%.

Keywords : Time-frequency analysis, micro-Doppler signals, SVM classification, machine learning, deep learning, human activity recognition, CNNs.

ملخص

يجذب التعرف على النشاط البشري (HAR) باستخدام إشارات دوبلر الدقيقة اهتمامًا متزايدًا، لا سيما في تطبيقات المراقبة والقياسات الحيوية والأمن المدني والعسكري. اعتمدت معظم الدراسات السابقة على كاميرات الفيديو وأجهزة استشعار أخرى محمولة لجمع بيانات النشاط البشري. ومع ذلك، فإن العيب الرئيسي لأنظمة الرؤية هو محدوديتها في البيئات التي تكون فيها الرؤية منخفضة. إضافة إلى ذلك، فإن انتهاك الخصوصية قد يؤثر سلبيًا على سلامة المستخدمين وثقتهم بأنظمة الرعاية الصحية خصوصًا. لذلك، يُعدّ الحفاظ على خصوصية المستخدم وأمن بياناته أمرًا بالغ الأهمية لمراقبة الصحة عن بُعد، وكذلك في كل ما يتعلق بالتطبيقات العسكرية. تتميز أجهزة استشعار الرادار بميزة التقاط بيانات النشاط البشري مع الحفاظ على خصوصية المستخدم. من هذا المنظور، يركز هذا العمل على كشف وتصنيف حركات المشي والجري البشرية، سواءً قام بها شخص واحد أو مجموعة أشخاص، من خلال الاستفادة من التحليل الزمني-الترددى لإشارات دوبلر الدقيقة.

بدنًا ذي بدأ، نقوم بمعالجة الإشارات الرادارية باستخدام تحليل زمني-ترددى عالي الدقة. من بين الطرق المتوفرة، تم استعمال مجموعة محددة من التوزيعات الزمنية-الترددية التريبعية لتحويل المخططات الزمنية-الترددية للإشارات الرادارية الملتقطة إلى صور ملونة مدخلة للمصنفات. على وجه التحديد، نستخدم توزيع شريط-بلوشراني المستخلص من نواة كثير حدود ذات سند محصور (PCBD) لاستخراج السمات المميزة من فئات مختلفة من الحركة البشرية. تُستخدم هذه الميزات بعد ذلك للتصنيف التلقائي باستخدام خوارزميات الذكاء الاصطناعي. نطبق أساليب التعلم الآلي، بما في ذلك آلة الدعم المتجه (SVM). بالإضافة إلى ذلك، ندمج مناهج التعلم العميق، مثل الشبكات العصبية التلافيفية (CNNs)، لتحسين متانة ودقة التصنيف. تؤكد النتائج التي تم الحصول عليها قوة نماذج CNN المستخدمة جنبًا إلى جنب مع التحليل الزمني-الترددى الذي أجراه توزيع الـ PCBD، مما أدى إلى تحقيق دقة اختبار مثالية بنسبة 100%.

الكلمات المفتاحية: التحليل الزمني-الترددى، إشارات دوبلر الدقيقة، التصنيف، آلة الدعم المتجه، التعلم الآلي، التعلم العميق، التعرف على النشاط البشري، شبكات CNN.

Table des matières

Remerciement.....2

Dédicace.....3

Résumé.....5

Liste des abréviations.....10

Listes des figures.....11

Listes des tableaux.....14

Introduction Générale.....15

Chapitre I

Effet Doppler et micro Doppler.....17

I.1 Introduction.....18

I.2 Historique.....18

I.3 Définition et principe de l’effet Doppler.....19

 I.3.1 Exemple pratique sur l’effet Doppler20

I.4 Différents cas d’effet Doppler.....20

 I.4.1 Source et observateur immobiles.....20

 I.4.2 Source immobile/ récepteur s’approche.....21

 I.4.3 Source immobile/ récepteur s’éloigne.....21

I.5 Quelques applications de l’effet Doppler.....22

 I.5.1 L’effet Doppler en médecine diagnostique.....22

 I.5.2 Les radars de vitesse.....23

I.6 L’effet micro- Doppler.....23

 I.6.1 Définition.....23

I.7 La signature24

I.8 Les application.....25

 I.8.1 Application courante de l’effet micro-doppler25

 I.8.2 Application émergentes de l’effet micro-doppler.....26

I.9 Conclusion.....26

Chapitre II

Analyse temps-fréquence.....27

II.1 Introduction.....	28
II.2 Les représentations linéaires.....	29
II.2.1 Transformée de Fourier à Court Terme (STFT).....	29
a. Définition.....	29
b. limites de la STFT.....	31
II.2.2 L’analyse temps-échelle (transformée en ondelette)	33
a. Définition et principe.....	33
II.3 Les représentations temps-fréquence quadratiques.....	33
II.3.1 Spectrogramme.....	33
a. Définition et Explication.....	33
b. Propriétés.....	34
II.3.2 Distribution de Wigner-Ville.....	34
II.3.3 Les distributions quadratiques basées sur des noyaux.....	36
II.3.3.1 Les distributions basées sur les noyaux à support compact KCS	37
a. Le noyau CB Polynomial (PCB)	37
II.4 Application de l’analyse temps-fréquence à la détection des mouvements humains.....	39
II.5 Conclusion	41
Chapitre III	
Classification des mouvements humains a base des signatures micro-Doppler.....	43
III.1 Introduction	44
III.2 Apprentissage automatique	44
III.2.1 Support Vector Machine (SVM).....	44
III.3 Apprentissage profond.....	45
III.3.1 Réseaux de Neurones Convolutifs (CNN).....	45
III.4 Implémentation pratique et résultats.....	48
III.4.1 Description de base de données.....	48
III.4.2 Classification avec SVM.....	49
III.4.3 Classification avec CNN.....	50
III.4.4 Les métriques de performance.....	53
III.4.5 Résultats obtenus	53
III.4.6 Graphiques de performance	55

Table des matières

III.4.7 Discussion.....	60
III.5 Conclusion.....	60
Conclusions Générale.....	62
Bibliographie.....	64

Liste des abréviations

S	source
R	récepteur
V_r	vitesse de récepteur
V_s	vitesse de source
V_s	vitesse de source
TF	Transformée de Fourier
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
HOG	Histogram of oriented gradient
SVM	Support Vector Machine
CNN	Convolutional Neural Network
VGG	Visual Geometry Group
DenseNet	Densely Connected Convolutional Network
ResNet	Residual Network

Liste des figures

Chapitre I

Figure 1.1 : Christian Doppler [3]	18
Figure 1.2 : Hippolyte Fizeau [4]	18
Figure 1.3: Différents cas de l'effet doppler [7]	19
Figure 1.4 : exemple d'ambulance (effet doppler) [8]	20
Figure 1.5 : Source et observateur immobiles (non effet doppler) [9]	20
Figure 1.6 : Le récepteur s'approche de la source [9]	21
Figure 1.7 : Echographie Doppler [11]	22
Figure 1.8 : Les radars de vitesse [13]	23
Figure 1.9 : Effet doppler et micro-Doppler [14]	24
Figure 1.10 : L'échocardiographie et Doppler cardiaque [17]	25

Chapitre II

Figure 2.1: (a) le signal chirp de $f_0=1\text{HZ}$ à $f_1= 50\text{HZ}$ et (b) FFT de signal chirp.....	28
Figure 2.2 : (a) le signal chirp de $f_1= 50\text{HZ}$ à $f_0=1\text{HZ}$ et (b) FFT de signal chirp.....	29
Figure 2.3 : (a) La STFT d'un signal contenant 4 composantes de fréquences constantes augmentant de $f_0= 10\text{HZ}$ à $f_1= 40 \text{HZ}$ avec $=10\text{Hz}$ (b) La STFT d'un signal avec le même contenu spectral que le signal en (a) avec des fréquences décroissantes	30
Figure 2.4 : Représentation temporelle d'un signal synthétique modulé linéairement en fréquence.....	31
Figure 2.5 : Le module de la TFCT d'une onde contenant deux signaux de modulation linéaire de fréquence (a) Hamming(64), (b) Hamming(128), (c) blackman (64), (d) blackman (128), (e) Kaiser (64), (f) Kaiser (128), (g) Gaussian (64), (h) Gaussian (128).....	32
Figure 2.6 : Distribution de wigner-ville d'un chirp linéaire [24]	35
Figure 2.7 : Distributions de Wigner-Ville d'un Signal constitué de deu chirps linéaires croisés.....	36

Figure 2.8 : La représentation TF d'un signal composé de 2 atomes Gaussiens. (a) WVD, et (b) PSWVD (h, g : Hamming, $L=15$). La suppression des interférences est clairement plus efficace en utilisant la PSWVD au détriment de la résolution légèrement dégradée.....36

Figure 2.9 : Le profil 2D du noyau PCB normalisé par rapport à son pic situé à l'origine ($t=0, \tau=0$) avec $\lambda=2,5$. (a) $\gamma=3$ et (b) $\gamma=10$ [25].....38

Figure 2.10 : La PCBD de deux signaux Doppler ($\lambda=4$). (a) $\gamma=3$, (b) $\gamma=9$ et (c) $\gamma=29$ [2]38

Figure 2.11 : Analyse temps-fréquence par la PCBD des signatures micro-Doppler ($\lambda=2.5, \gamma=19$). (a) Une personne qui marche et (b) une personne qui court [33].....40

Figure 2.12 : Analyse temps-fréquence par la PCBD des signatures micro-Doppler ($\lambda=2.5, \gamma=19$). (a) Un groupe de personnes marchant et (b) un groupe de personnes courant [33].....40

Figure 2.13 : Signatures micro-Doppler TF de six activités humaines distinctes générées par la PCBD ($\gamma=20$). (a) Marcher en avant et en arrière, (b) s'asseoir sur une chaise, (c) se lever d'une chaise, (d) se baisser pour ramasser quelque chose, (e) boire de l'eau debout, et (f) tomber frontalement.....41

Chapitre III

Figure 3.1 : L'architecture typique d'un réseau de neurone convolutif (CNN) [39].....46

Figure 3.2 : Architecture de VGG16 (Visual Geometry Group) [40].....46

Figure 3.3 : Architecture de VGG19 [41]47

Figure 3.4 : Architecture de DenseNet201 [42].....47

Figure 3.5 : Architecture de ResNet50 (a) Architecture globale (b) Architecture de chaque bloc résiduel [43].....47

Figure 3.6 : Description de la base de données48

Figure 3.7 : Schéma fonctionnel des méthodes de traitement appliquer aux image temps-fréquence des mouvements humains.....49

Figure 3.8 : Schéma détaillé de classification par SVM des images temps-fréquence après extraction des caractéristiques HOG.....50

Figure 3.9 : Schéma détaillé de classification par CNN des images temps-fréquence générées par la PCBD dans le cadre de transfert learning52

Liste des figures

Figure 3.10 : Exactitude d'entraînement et de validation par SVM en fonction du nombre de plis K en validation croisées.....	55
Figure 3.11 : Courbe d'exactitude d'entraînement et de validation en fonction du nombre d'époques pour le modèle VGG16.....	56
Figure 3.12 : Courbe de perte d'entraînement et de validation en fonction du nombre d'époques pour modèle VGG16.....	56
Figure 3.13 : Courbe d'exactitude d'entraînement et de validation en fonction du nombre d'époques pour le modèle VGG19.....	57
Figure 3.14 : Courbe de perte d'entraînement et de validation en fonction du nombre d'époques pour modèle VGG19.....	57
Figure 3.15 : Courbe d'exactitude d'entraînement et de validation en fonction du nombre d'époques pour le modèle DenseNet201.....	58
Figure 3.16 : Courbe de perte d'entraînement et de validation en fonction du nombre d'époques pour modèle DenseNet201.....	58
Figure 3.17 : Courbe d'exactitude d'entraînement et de validation en fonction du nombre d'époques pour le modèle ResNet50.....	59
Figure 3.18 : Courbe de perte d'entraînement et de validation en fonction du nombre d'époques pour modèle ResNet50.....	59

Liste des tableaux

Chapitre III

Tableau 3.1 : Caractéristiques techniques du radar et description de la base de données utilisée.....	48
Tableau 3.2 : Les métriques de performance utilisées pour évaluation et comparaison...53	
Tableau 3.3 : Les performances des modèles (SVM, VGG16, VGG19, ResNet50 DenseNet201)	54
Tableau 3.4 : Le temps d'entraînement et le temps inférence de chaque modèle.....	54
Tableau 3.5 : Matrice de confusion des modèle CNN.....	60

Introduction Générale

L'analyse des mouvements humains est un domaine de recherche en pleine expansion en raison de ses nombreuses applications dans divers secteurs tels que la surveillance, la biométrie, la rééducation médicale et la sécurité. Parmi les différentes approches développées pour la reconnaissance des activités humaines, l'analyse des signatures micro-Doppler issues des radars Doppler constitue une alternative prometteuse aux systèmes basés sur la vision, notamment dans les environnements où la visibilité est réduite.

Dans ce mémoire, nous nous intéressons à la détection des mouvements de marche et de course, réalisés par une personne seule ou par des groupes de personnes. Pour ce faire, nous exploitons l'analyse temps-fréquence des signaux micro-Doppler afin d'extraire des caractéristiques pertinentes propres à chaque type de mouvement. Ce choix se justifie par le fait que les signaux étudiés sont non-stationnaires, c'est-à-dire que leur contenu spectral varie en fonction du temps, faisant de l'utilisation d'une transformation conjointe en temps et en fréquence la solution la plus raisonnable et la plus efficace.

Dans ce contexte, les signaux micro-Doppler permettent d'extraire des informations précieuses sur la dynamique du mouvement humain. En effet, chaque type de mouvement, qu'il s'agisse de marcher, de courir, de sauter, de ramper, de boire de l'eau ou de tenir un revolver, produit une *signature spécifique* observable dans le domaine temps-fréquence (TF).

Après une étude approfondie des méthodes temps-fréquence, notre objectif principal de ce travail était d'évaluer objectivement l'efficacité de différentes méthodes de classification appliquées aux signaux micro-Doppler, et d'optimiser les performances de reconnaissance des mouvements humains grâce à l'intégration de techniques issues de l'intelligence artificielle, combinées à une analyse temps-fréquence particulière.

En effet, les diagrammes TF associées aux signatures micro-Doppler examinées sont générés à l'aide d'une distribution récente appelée PCBD pour Polynomial Chretien-Belouchrani Distribution. Cette présentation appartient à une famille spécifique de distributions temps-fréquence quadratiques basées sur des noyaux temps-retard à support compact (Kernels with Compact Support KCS).

Une fois les caractéristiques identifiées, nous mettons en œuvre des algorithmes d'intelligence artificielle pour la classification automatique des mouvements de marche et de course, notamment :

- Des méthodes d'apprentissage automatique (Machine Learning), plus spécifiquement Support Vector Machine (SVM) : Les images générées par PCBD sont utilisées pour entraîner ce modèle, après l'extraction des caractéristiques à l'aide de descripteurs définis manuellement.
- Des méthodes plus performantes basées sur l'apprentissage profond (Deep Learning), à savoir les réseaux de neurones convolutifs (Convolutional Neural Networks CNNs), dans le but d'améliorer la précision de la classification. Parmi les architectures les plus utilisées dans la littérature, nous avons examiné les performances de VGG16, VGG19, ResNet50, et DenseNet201. Ces modèles CNN pré-entraînés utilisés comme des classifieurs sont alimentés par des données provenant des diagrammes TF basés sur PCBD fournis, convertis en images RVB.

Le reste de ce mémoire est organisé comme suit :

- Dans un premier chapitre, nous présentons les définitions et les bases théoriques des signaux Doppler et micro-Doppler,
- Le deuxième chapitre est consacré à l'analyse temps-fréquence des signaux non-stationnaires à travers l'utilisation des représentations linéaires et quadratiques, en mettant en évidence les avantages et les limites propres à chacune de ces approches, ainsi que l'application de cette analyse à la détection des mouvements humains,
- Le troisième chapitre est consacré aux méthodes de classification basées sur l'apprentissage automatique, telles que le SVM, ainsi que sur l'apprentissage profond, en particulier les réseaux de neurones convolutifs (CNN) avec différentes architectures telles que VGG16, VGG19, ResNet50 et DenseNet201. L'objectif est d'examiner le choix du classificateur sur les performances de détection de deux types de mouvements, à savoir la marche et la course, pour un individu et des groupes d'individus.
- Enfin, le document conclut par des conclusions et des recommandations pour les projets futurs.

Chapitre I

Effet Doppler et micro-Doppler

I.1 Introduction

La détection et l'analyse des mouvements humains à l'aide de signaux radar reposent sur des principes physiques fondamentaux, parmi lesquels l'effet Doppler occupe une place centrale. Découvert par Christian Doppler en 1842, cet effet traduit la variation apparente de la fréquence d'une onde en fonction de la vitesse relative entre la source et le récepteur. Il est largement exploité dans divers domaines [1].

Lorsqu'un radar transmet un signal électromagnétique à une cible, le signal interagit avec la cible et revient au radar. Les changements dans les propriétés du signal renvoyé reflètent les caractéristiques d'intérêt pour la cible [2]. Lorsque la cible se déplace à une vitesse constante, la fréquence porteuse du signal renvoyé sera décalée. C'est ce qu'on appelle l'effet Doppler. Dans le cadre des systèmes radar, ce phénomène permet d'extraire des informations cruciales sur la vitesse radiale des cibles en mouvement [2].

Cependant, les mouvements complexes, tels que ceux des êtres humains, induisent des variations plus fines de la fréquence, appelées signatures micro-Doppler. Introduit par Victor Chen, le phénomène micro-Doppler résulte des oscillations, rotations ou vibrations des différentes parties d'un objet en mouvement. Dans le cas d'un piéton, par exemple, les mouvements des bras et des jambes génèrent des composantes fréquentielles supplémentaires qui enrichissent la signature Doppler globale [1].

I.2 Historique

Le nom de ce phénomène vient du physicien Christian Doppler, 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 [3].



Figure 1.1 : Christian Doppler [4].



Figure 1.2 : Hippolyte Fizeau [5].

Christian Doppler (1803-1853) est un mathématicien et physicien autrichien. Il s'est rendu célèbre par une découverte qui porte maintenant son nom : l'effet Doppler. Sa publication la plus célèbre s'appelle « Sur la lumière colorée des étoiles doubles et d'autres étoiles du ciel ». Un peu plus tard et indépendamment, Hippolyte Fizeau découvre lui aussi ce phénomène et il l'étend aux ondes lumineuses. Ce phénomène s'applique à tous les types d'onde (sonores, ultrasonores et mécaniques à la surface de l'eau par exemple). Pour les ondes lumineuses, on emploiera le terme d'effet Doppler-Fizeau Figure 1.2 [3].

I.3 Définition et principe de l'effet Doppler

L'effet Doppler c'est le phénomène qui caractérise le changement de fréquence de l'onde captée par un récepteur lorsque l'émetteur et le récepteur sont en mouvement relatif. Il est particulièrement important dans les domaines des ondes acoustique, lumineuses et électromagnétiques (comme les ondes radar) [6]. Donc, si quelque chose émet une onde en se déplaçant par rapport le récepteur, la fréquence est différente de celle émise. Il y a alors différents cas Figure I.3 [6] :

- ❖ Si la source et le récepteur sont immobiles
- ❖ Si la source s'approche du récepteur immobile (ou si le récepteur s'approche de la source immobile)
- ❖ Si la source s'éloigne du récepteur immobile (ou si le récepteur s'éloigne de la source immobile)
- ❖ Si la source et le récepteur sont en mouvement




Figure I.3: Différents cas de l'effet Doppler [7].

I.3.1 Exemple pratique sur l'effet Doppler

Comme montré sur la Figure 1.4, quand une ambulance se rapproche, on entend un son à haute fréquence. Lorsqu'elle est passée et s'éloigne, le son perçu est à une fréquence plus basse.




Figure 1.4 : Exemple de l'effet Doppler : Une ambulance [8].

I.4 Différents cas d'effet Doppler

I.4.1 Source et observateur immobiles

Ici, on ne constate pas l'effet Doppler, puisque la source et le récepteur sont immobiles Figure 1.5. L'onde sonore a une célérité v , une longueur d'onde λ , une période T , et une fréquence f . L'observateur perçoit une onde sonore ayant les mêmes caractéristiques [3].

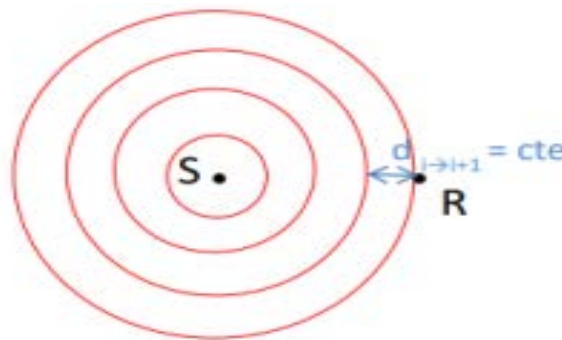


Figure 1.5 : Source et observateur immobiles (pas d'effet Doppler) [9].

Dans une telle situation, l'expression mathématique est donnée par :

$$f' = f \quad (\text{I.1})$$

Où :

- f est la fréquence de la source.
- f' est la fréquence reçue.

Par conséquent, aucune variation de fréquence n'est observée d'où l'absence de l'effet Doppler.

Nous présentons ci-après les différents cas de l'effet Doppler qui correspondent à notre étude, c'est-à-dire la source immobile et le récepteur en mouvement.

I.4.2 Source immobile/récepteur s'approche

Lorsque le récepteur se rapproche de la source, il intercepte les fronts d'onde plus rapidement. Cela signifie qu'il perçoit une fréquence plus élevée que celle émise par la source [1].

Le schéma de la Figure 1.6 illustre le principe du décalage Doppler dans le cas source immobile et récepteur s'approche. L'émetteur (S) envoie une onde qui se propage à une vitesse v . Avant le mouvement, le signal parcourt une distance $d=v \times T$. Lorsque la cible (R) se déplace avec une vitesse v_r , la distance parcourue par le signal est modifiée en fonction du temps $d_r(t)=v \times T - v_r \times t$. Ce décalage induit un changement de fréquence, caractéristique essentiel pour analyser les mouvements humains via un radar.

$$f' = f \times (v + v_r / v) \quad (I.2)$$

où :

- v est la vitesse du son ou de la propagation de l'onde,
- v_r est la vitesse du récepteur (positive lorsqu'il s'approche),
- f est la fréquence de la source,
- f' est la fréquence perçue.

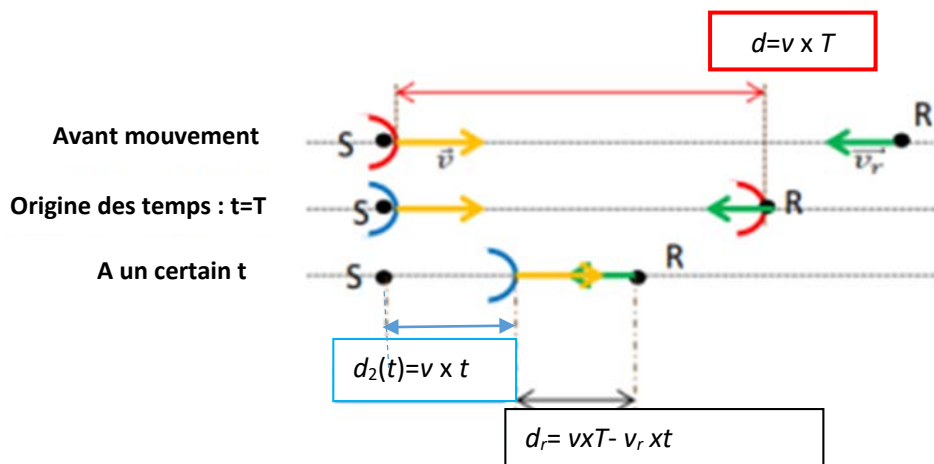


Figure 1.6 : Le récepteur s'approche de la source [9].

I.4.3 Source immobile/récepteur s'éloigne

De la même manière, dans le cas où la source est immobile et le récepteur s'éloigne, le récepteur intercepte les fronts d'onde à une fréquence plus basse que celle émise par la source. Ce phénomène est dû à l'augmentation de la distance entre le récepteur et la source, ce qui entraîne

Une diminution du nombre d'ondes reçues par unité de temps. Cette diminution se traduit par un décalage Doppler vers les basses fréquences [1].

La fréquence perçue par le récepteur est alors exprimée par :

$$f' = f \times (v - v_r) / v \quad (\text{I.3})$$

I.5 Quelques applications de l'effet Doppler

I.5.1 L'effet Doppler en médecine diagnostique

L'une des applications les plus courantes de l'effet Doppler en médecine est son utilisation dans les techniques d'imagerie médicale, telles que l'échographie Doppler Figure 1.7. Cette technique permet de mesurer les mouvements des fluides tels que le sang dans les vaisseaux sanguins, ou encore les mouvements du cœur. L'effet Doppler permet ainsi de détecter d'éventuelles anomalies dans le flux sanguin, comme des caillots de sang ou des rétrécissements des vaisseaux [10].

L'échographie Doppler est non invasive et ne nécessite pas l'utilisation de rayonnements ionisants, ce qui en fait une technique sûre et largement utilisée. De plus, elle permet d'obtenir des informations en temps réel sur le flux sanguin, ce qui peut être particulièrement utile lors de l'évaluation de patients atteints de maladies cardiaques ou de troubles de la circulation sanguine [10].




Figure 1.7 : Echographie Doppler [11].

I.5.2 Les radars de vitesse

Les radars de vitesse utilisés pour contrôler la vitesse des véhicules se basent sur l'effet Doppler. Ces radars émettent des ondes électromagnétiques (généralement des micro-ondes) vers un véhicule en mouvement. L'onde est réfléchiée par le véhicule et revient au radar avec une fréquence modifiée en raison de l'effet Doppler. En mesurant la différence de fréquence, il est possible de calculer la vitesse du véhicule Figure 1.8 [12].

La formule utilisée pour les radars de vitesse est souvent une version simplifiée de celle décrite ci-dessus. Si θ est l'angle entre le faisceau du radar et la direction du véhicule, la fréquence Doppler est donnée par [12] :

$$\Delta f = 2 f v \cos(\theta) / c \quad (\text{I.4})$$

Où :

- Δf est la variation de fréquence mesurée.
- f est la fréquence émise par le radar.
- v est la vitesse du véhicule.
- c est la vitesse de la lumière.



Figure 1.8 : Les radars de vitesse [13].

I.6 L'effet micro-Doppler

I.6.1. Définition :

Le micro-Doppler fait référence à un effet Doppler à petite échelle, souvent observé dans les signaux radar ou sonar lorsqu'ils rencontrent des objets en mouvement, en particulier ceux qui présentent des variations dans leurs caractéristiques de mouvement, comme les objets vibrants ou oscillants. Cela se distingue du Doppler classique, qui concerne des mouvements globaux d'un objet comme le montre la Figure 1.9. Le micro-Doppler peut être utilisé pour analyser des phénomènes comme le mouvement des membres d'une personne (par exemple, les bras ou les jambes pendant la marche) ou les vibrations d'une machine.

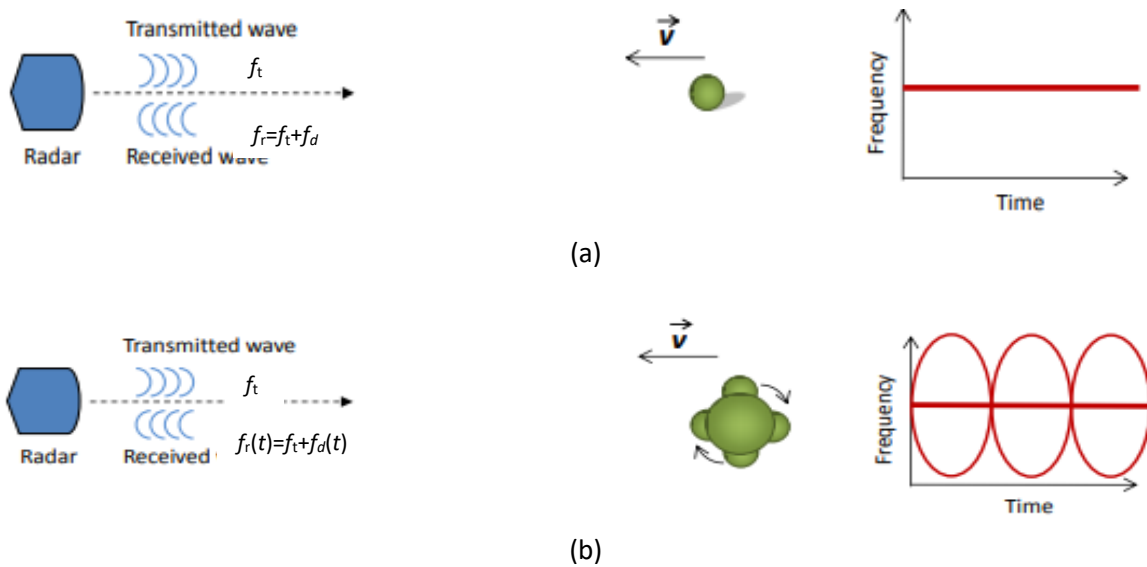


Figure 1.9 : (a) Effet Doppler et (b) effet micro-Doppler [14].

Le micro-doppler produit un décalage de fréquence qui dépend de la vitesse, de la direction, et de la fréquence de l'oscillation ou de la vibration de l'objet en question. Dans les applications radar, cela permet d'obtenir des informations supplémentaires sur la dynamique de l'objet détecté, comme sa posture ou ses caractéristiques de mouvement fines [15].

I.7 La signature micro-Doppler

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, mais aussi de la nature du mouvement lui-même. Lorsqu'on parle de la détection des mouvements humains, les signatures doppler peuvent être différentes en fonction de l'activité (marche, course, geste spécifique), car chaque type de mouvement génère un profil de doppler distinct [16].

Illustration des différences

***Marche :** Une personne qui marche en ligne droite produit un profil doppler régulier à fréquence plus basse qui change légèrement en raison du mouvement du corps, des bras et des jambes [1].

***Course :** Les coureurs génèrent des courbes avec des pics plus fréquents, ou les oscillations de fréquence sont plus prononcées en raison de la vitesse de déplacement et de l'amplitude des gestes [1].

***Gestes spécifiques :** Si une personne lève le bras ou effectue un geste rapide, la signature doppler culminera à une fréquence plus élevée et pourra varier en fonction de la direction et de l'amplitude du mouvement (par exemple 5-10 Hz) [1].

I.8 Les applications

Les applications du micro-doppler sont nombreuses et concernent plusieurs domaines technologiques.

I.8.1. Application courante de l'effet micro-doppler

a. Radars à micro-Doppler

Ces radars sont utilisés pour détecter et suivre des objets en mouvement, tels que des véhicules, des avions ou des personnes. Ils peuvent également être utilisés pour identifier le type d'objet en mouvement, par exemple un drone ou un oiseau [17].

b. Imagerie médicale

L'effet micro-doppler peut être utilisé pour créer des images du flux sanguin dans le corps. Cela peut être utile pour diagnostiquer des problèmes de santé tels que des maladies cardiaques ou des accidents vasculaires cérébraux comme l'échocardiographie et le doppler cardiaque Figure 1.10 [17].




Figure 1.10 : L'échocardiographie et Doppler cardiaque [17].

c. 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 [18].

d. Robotique

Les robots peuvent utiliser l'effet micro-doppler pour se déplacer dans leur environnement et éviter les obstacles.

I.8.2. Application émergente de l'effet micro-doppler :*a. Reconnaissance faciale*

L'effet micro-doppler peut être utilisé pour identifier une personne à partir de ses mouvements subtils, tels que les mouvements de sa tête ou de ses yeux. [17]

b. Analyse du comportement

L'effet micro-doppler peut être utilisé pour analyser le comportement d'une personne, par exemple pour détecter le stress ou la fatigue [17].

I.9 Conclusion

Dans ce chapitre, nous avons exploré les fondements théoriques de l'effet Doppler et du micro-Doppler, deux phénomènes physiques essentiels à l'analyse des signatures de mouvement dans les systèmes radar. Nous avons tout d'abord introduit l'effet Doppler classique, qui traduit la variation de fréquence d'une onde électromagnétique en fonction du déplacement relatif entre l'émetteur et la cible. Cette propriété est largement exploitée dans de nombreuses applications, notamment en télédétection, en surveillance et en suivi des objets en mouvement.

Nous avons ensuite approfondi l'effet micro-Doppler, qui résulte des mouvements internes d'une cible, tels que les oscillations, les vibrations ou les mouvements segmentaires du corps humain. Contrairement à l'effet Doppler global, le micro-Doppler permet d'obtenir une signature plus détaillée des dynamiques de mouvement, offrant ainsi un moyen d'identifier et de caractériser différents types d'activités humaines.

Chapitre II

Analyse temps-fréquence des signaux non-stationnaires

II.1 Introduction

L'analyse temps-fréquence est une approche essentielle dans nombreux domaines scientifiques et techniques, notamment en télécommunications, en traitement du signal radar et en biomédecine, permettant de caractériser des signaux dont les propriétés spectrales varient dans le temps, contrairement à l'analyse classique en domaine fréquentiel, qui suppose implicitement la stationnarité du signal [18]. Cette non-stationnarité en fréquence s'applique parfaitement sur les signaux micro-Doppler.

La Transformée de Fourier (TF) a longtemps été l'outil privilégié pour analyser les signaux, car elle permet d'extraire leur contenu fréquentiel. Toutefois, elle ne fournit aucune information sur la localisation temporelle des fréquences, elle analyse le contenu fréquentiel global du signal mais ne tient pas compte de l'évolution temporelle des fréquences [18]. Comme montrent les Figure 2.1 et 2.2, les deux signaux FM linéaires (linear chirps) couvrent la même plage de fréquences [1 Hz, 50 Hz], et par conséquent leur FFT donne une distribution d'énergie similaire, bien que l'évolution fréquentielle en fonction du temps soit nettement différente. En fait, la raison d'être de l'analyse temps-fréquence est de pouvoir déterminer avec précision le début et la fin de chaque évènement fréquentiel (localisation temps-fréquence).

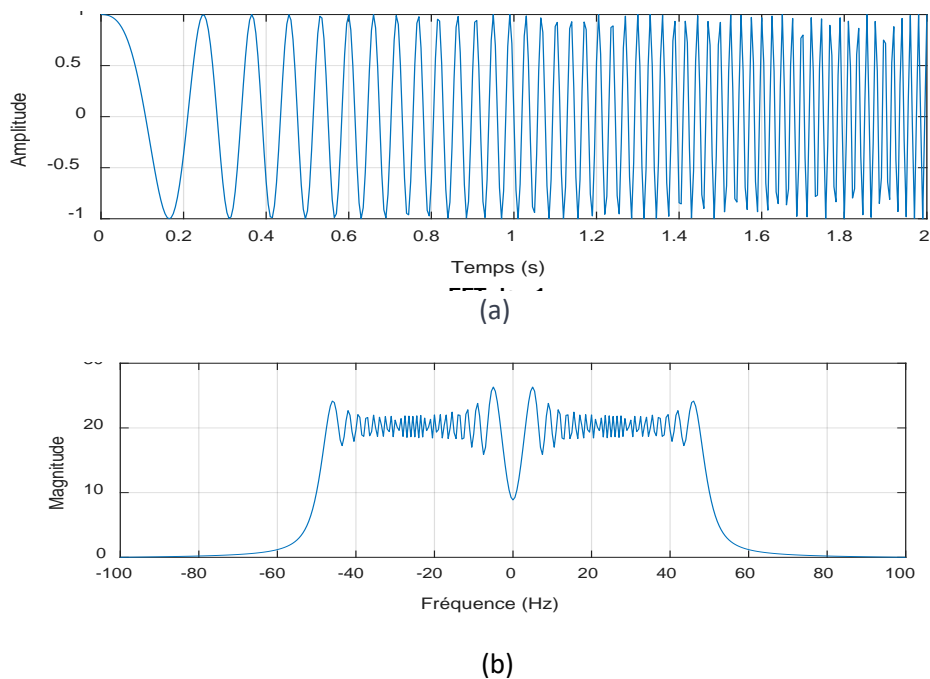


Figure 2.1: (a) Un signal FM linéaire de fréquence variant de $f_0=1$ Hz à $f_1=50$ Hz et (b) FFT du signal en (a).

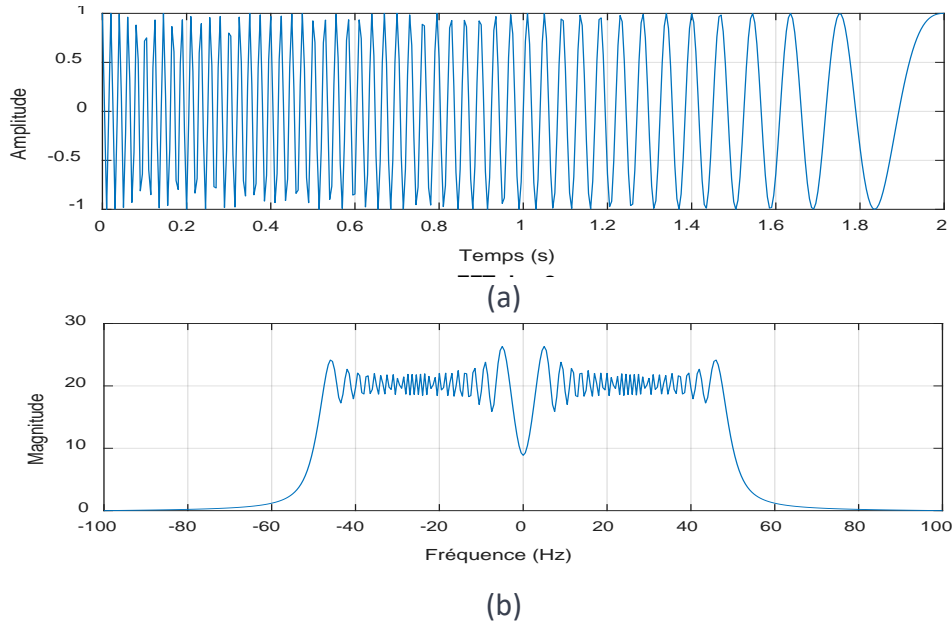


Figure 2.2 : (a) Un signal FM linéaire de fréquence variant de $f_i=50$ Hz à $f_0=1$ Hz et (b): FFT du signal en (a).

L'analyse temps-fréquence permet alors d'obtenir une représentation conjointe du contenu fréquentiel d'un signal et de son évolution temporelle [18]. Les outils couramment utilisés pour l'analyse temps-fréquence incluent principalement deux grandes catégories : les représentations linéaires telle que la transformées de Fourier à court terme (STFT) ainsi que les ondelettes, et les représentations bilinéaires encore appelées les distributions temps-fréquence quadratiques dont les plus performantes sont basées sur des noyaux jouant le rôle d'un filtre 2D dans le domaine Doppler-retard.

II.2 Les représentations linéaires

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

a. Définition

La Transformée de Fourier à Court Terme (STFT) est une méthode d'analyse temps-fréquence introduite par Dennis Gabor en 1946, permettant d'examiner les variations spectrales des signaux non stationnaires dont le contenu fréquentiel évolue au cours du temps [19]. Elle a été développée pour surmonter les limitations de la Transformée de Fourier (FFT), qui ne permet pas d'analyser efficacement les signaux dont les caractéristiques spectrales varient dans le temps [18], la STFT d'un signal $x(t)$ est définie par :

$$STFT_x(t, f) = \int_{-\infty}^{+\infty} x(\tau) w(\tau - t) e^{-j2\pi f\tau} d\tau \quad (\text{II.1})$$

où :

- $STFT_x(t, f)$ 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,
- $e^{-j2\pi f\tau}$ 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 [18], comme montre les Figures 2.3 et 2.4.

La Figure 2.3 présente la STFT de deux signaux générés avec une fréquence d'échantillonnage de 200 Hz. Le premier signal consiste en quatre composantes de fréquences constantes augmentant de $f_0=10$ Hz à $f_1=40$ Hz avec $\Delta f=10$ Hz, tandis que le deuxième signal se compose des mêmes termes mais avec un ordre décroissant. Une fenêtre de Hamming de largeur $L=100$ est utilisée pour calculer la transformée de Fourier à court terme. On voit clairement que la STFT arrive à différencier entre les deux signaux dans le plan TF contrairement à la transformée de Fourier.




Figure 2.3 : (a) La STFT d'un signal contenant 4 composantes de fréquences constantes augmentant de $f_0=10$ Hz à $f_1=40$ Hz avec $\Delta f=10$ Hz et (b) la STFT d'un signal multi-composants avec le même contenu spectral que le signal en (a) mais avec des fréquences décroissantes.

b. Limites de la STFT

Malgré son utilité, la STFT présente plusieurs limitations importantes. La plus notable est le compromis entre la résolution temporelle et la résolution fréquentielle, qui est inhérent au principe d'incertitude de Heisenberg-Gabor. Ce principe stipule que les produits de la précision temporelle Δt et de la précision fréquentielle Δf doivent satisfaire la relation suivante [18] :

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

Ainsi, il est impossible d'obtenir simultanément une haute précision temporelle et fréquentielle. Si la fenêtre choisie est courte, la localisation temporelle sera précise mais la résolution fréquentielle sera faible, tandis qu'une fenêtre large améliorera la précision fréquentielle mais dégradera la précision temporelle [18].

De plus, le choix de la fenêtre a un impact direct sur la représentation temps-fréquence. Une fenêtre inappropriée peut entraîner des artefacts qui dégradent considérablement la localisation des événements spectraux dans le temps [18].

Pour illustrer pratiquement ces limites, prenant l'exemple de la Figure 2.4 qui concerne un signal non-stationnaire contenant deux composantes modulées linéairement en fréquence (LFMs). La première composante croît de 500 Hz à 1500 Hz, tandis que le deuxième décroît de 1500 Hz à 500 Hz [20].




Figure 2.4 : Représentation temporelle d'un signal synthétique composé de 2 composantes modulées linéairement en fréquence.

La Figure 2.5 illustre le module de la STFT de ce signal non-stationnaire. Différentes fenêtres d'analyse sont utilisées avec une largeur $L = 64$ puis 128.

D'abord, on observe que la largeur de la fenêtre influe directement sur la résolution : Les fenêtres de largeur 128 offrent une meilleure localisation fréquentielle que celles avec une largeur de 64. Cela s'explique par le fait que la STFT est capable de localiser correctement la première composante fréquentielle (allant de 500 Hz à 1500Hz), et la deuxième composante débutant de

1500 Hz et se terminant à 500 Hz, alors que la localisation temporelle est sans importance. Par conséquent, la localisation fréquentielle est d'autant plus précise que L augmente. De plus, les termes d'interférence sont mieux réduits en utilisant respectivement la fenêtre de Blackman et la fenêtre de Kaiser. Cette dernière produit la meilleure résolution fréquentielle.




Figure 2.5 : Le module de la STFT d'un signal contenant deux composantes croisées modulées en fréquence. (a) Hamming ($L=64$), (b) Hamming ($L=128$), (c) Blackman ($L=64$), (d) Blackman ($L=128$), (e) Kaiser ($L=64$), (f) Kaiser ($L=128$), (g) Gaussian ($L=64$), (h) Gaussian ($L=128$).

II.2.2 L'analyse temps-échelle (transformée en ondelette)

a. Définition et principe

La Transformée en Ondelettes Continue (CWT, Continuous Wavelet Transform) est une technique d'analyse temps-fréquence qui permet une représentation plus flexible des signaux non-stationnaires, contrairement à la STFT qui utilise une fenêtre de taille fixe [21].

L'idée principale de la CWT est d'analyser un signal en le projetant sur des versions dilatées et translatées d'une fonction de base appelée ondelette mère [21]. Cette ondelette est dilatée par un facteur d'échelle et translatée dans le temps, ce qui permet d'obtenir une résolution adaptative en fréquence et en temps [21]. La CWT est généralement défini par :

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

où :

ψ est la fonction d'ondelettes de base,

b : la translation,

a : le facteur de dilatation.

Une explication intuitive de l'équation précédente (II.3) :

La projection du signal $x(t)$ sur la fonction de base des ondelettes ψ , obtenue par décalage de t et changement d'échelle a , est représentée par $W(a,b,x,\psi)$. La fonction de base des ondelettes ψ , peut être adaptée en fonction des besoins spécifiques, mais sa forme doit être déterminée avant l'analyse [21].

II.3 Les représentations temps-fréquence quadratiques

Les représentations temps fréquences quadratiques du signal ne sont rien que des distributions temps-fréquence de l'énergie [19].

II.3.1 Spectrogramme

a. Définition

Le spectrogramme constitue une représentation temps-fréquence qui découle directement de la transformée de Fourier à court terme. Il est défini comme le module carré de la STFT [19]:

$$S_x(t, f) = \left| \int_{-\infty}^{+\infty} x(\tau) w(\tau - t) e^{-j2\pi f\tau} d\tau \right|^2 \quad (\text{II.4})$$

Où :

$|\cdot|^2$ présente le module au carré.

b. Propriétés

- Covariance temps et fréquence :

Une conséquence immédiate de la définition du spectrogramme est sa capacité à préserver les décalages temporels et fréquentiels :

$$y(t)=x(t-t_0) e^{j2\pi f_0 t} \Rightarrow S_y(t,f)=S_x(t-t_0, f-f_0) \quad (\text{II.5})$$

Par conséquent, le spectrogramme fait partie de la classe des distributions temps-fréquences quadratiques qui sont covariantes par translation en temps et en fréquence [20].

- Résolution temps-fréquence :

Puisque le spectrogramme est calculé à partir de l'amplitude au carré de la STFT, il est évident que sa résolution temps-fréquence est limitée de la même manière que celle de la STFT. En particulier, il y a encore un compromis entre la résolution temporelle et la résolution fréquentielle. Cette limitation de résolution est la principale limitation de cette représentation [20].

II.3.2 Distribution de Wigner-Ville

La technique originale d'analyse du signal temps-fréquence (ASTF) est la distribution de Wigner-Ville (WVD). Son nom vient d'E. Wigner qui l'a proposée en mécanique quantique [22] et de J. Ville [23], le premier chercheur à l'utiliser pour expliquer la notion de fréquence instantanée en théorie des communications [24].

Ces transformées sont appelées distributions temps-fréquence bilinéaires ou quadratiques car leur représentation est formulée par la comparaison multiplicative du signal avec lui-même [24]. La distribution de Wigner-Ville, qui date du début des années 1930 [22], est la plus ancienne transformée et la technique quadratique énergétique prédominante dans le domaine de l'analyse des signaux temps-fréquence. Elle est définie comme [22,23]:

$$WVD_x(t, f) = \int_{-\infty}^{+\infty} x(t + \tau/2) x^*(t - \tau/2) e^{-j2\pi f\tau} d\tau \quad (\text{II.6})$$

où $x^*(t)$ est le conjugué complexe de $x(t)$.

La Figure 2.6 présente le tracé WVD d'un chirp linéaire. On constate que la distribution permet à ce signal particulier une localisation parfaite en temps et en fréquence, ce qui constitue l'une des nombreuses propriétés mathématiques souhaitables qui font de la WVD une référence pour les autres distributions quadratiques [24].

Cependant, en raison de sa nature bilinéaire, la WVD a des résultats de temps-fréquence trompeurs dans le cas de signaux à plusieurs composants en raison de la présence de termes croisés [25], également appelés termes d'interférence ou artefacts. Ces derniers dépassent même les amplitudes des composantes propres au signal analysé [24].

Par exemple, la WVD du signal à 2 composants $\tilde{x}(t) = x_1(t) + x_2(t)$ est [24]:

$$WVD_{\tilde{x}}(t, f) = WVD_{x_1}(t, f) + WVD_{x_2}(t, f) + 2\text{Re}[WVD_{x_1x_2}(t, f)] \quad (\text{II.7})$$

où $WVD_{x_1}(t, f)$ et $WVD_{x_2}(t, f)$ sont respectivement la WVD des signaux $x_1(t)$ et $x_2(t)$. Le dernier terme $WVD_{x_1x_2}(t, f)$ est la WVD croisée de $x_1(t)$ et $x_2(t)$; il est donné par:

$$WVD_{x_1x_2}(t, f) = \int_{-\infty}^{+\infty} x_1(t + \tau/2) x_2^*(t - \tau/2) e^{-j2\pi f\tau} d\tau \quad (\text{II.8})$$

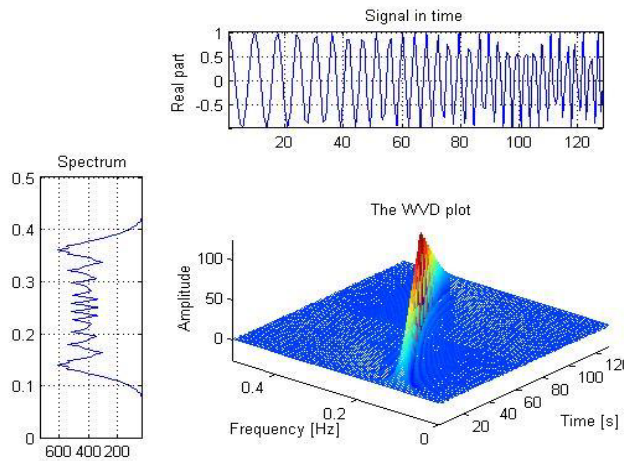


Figure 2.6 : La distribution de Wigner-Ville d'un chirp linéaire [24]. La localisation TF est dans ce cas parfaite.

La Figure 2.7 représente la WVD d'un signal multi-composant avec deux chirps FM linéaires, l'un avec un support de fréquence croissant de 0,1 à 0,4 Hz et l'autre avec un support de fréquence décroissant de 0,4 à 0,1 Hz. Les termes oscillatoires sont appelés termes croisés et conduisent à dégrader la lisibilité des diagrammes temps-fréquence [24]. Pour remédier à ce problème, des versions lissées de la WVD ont été introduites. Parmi ces dernières se trouve la pseudo WVD lissée (Smoothed Pseudo WVD ou SPWVD). Le prix à payer pour cette amélioration considérable est l'inclusion de deux fenêtres d'analyse indépendantes, l'une dans le domaine temporel et l'autre dans le domaine fréquentiel. Ce double lissage réduit les termes croisés, offrant une représentation plus précise du signal, bien qu'avec une résolution légèrement inférieure à celle de la WVD [26]. L'exemple de la Figure 2.8 illustre cette situation. La SPWVD d'un signal $x(t)$ est donnée par :

$$SPWVD_x(t, f; g, h) = \int_{-\infty}^{+\infty} h(\tau) \int_{-\infty}^{+\infty} g(s - t) x(s + \tau/2) x^*(s - \tau/2) ds e^{-j2\pi f\tau} d\tau \quad (\text{II.9})$$




Figure 2.7 : La distribution de Wigner-Ville d'un signal constitué de deux chirps linéaires croisés.

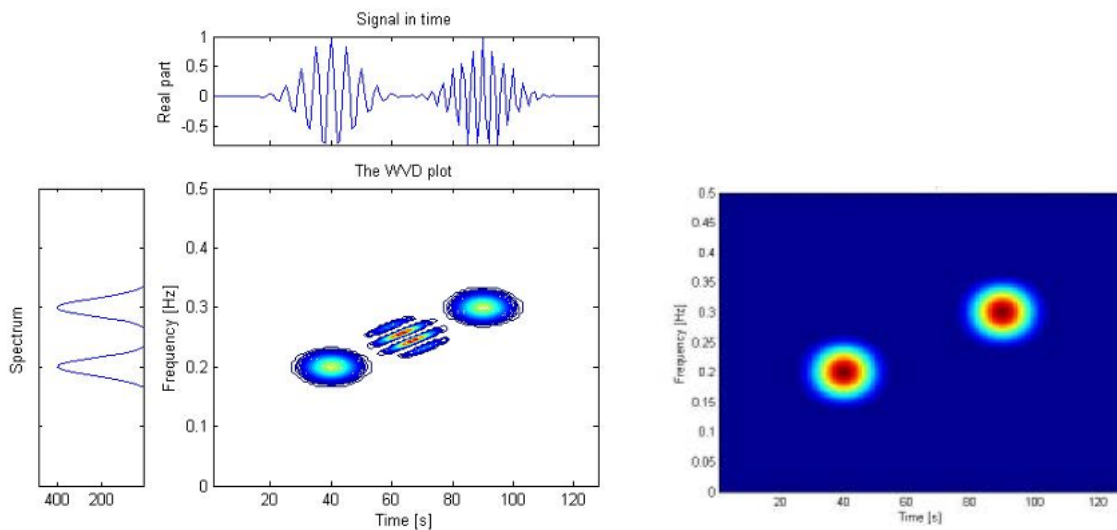


Figure 2.8 : La représentation TF d'un signal composé de 2 atomes Gaussiens. (a) WVD, et (b) PSWVD (h, g : Hamming, $L=15$). La suppression des interférences est clairement plus efficace en utilisant la PSWVD au détriment de la résolution légèrement dégradée.

II.3.3 Les distributions quadratiques basées sur des noyaux

Parmi les propriétés souhaitables d'une distribution d'énergie temps-fréquence, deux d'entre eux sont d'une importance particulière : la covariance temporelle et la covariance fréquentielle. En effet, ces propriétés garantissent que, si le signal est retardé dans le temps et modulé, sa distribution temps-fréquence est translatée des mêmes quantités dans le plan temps-fréquence. Il a été montré que la classe des distributions temps-fréquence (DTFs) d'énergie vérifiant ces propriétés de covariance possède l'expression générale suivante [27] :

$$TFD_x(t, f, \phi) = \iiint_{-\infty}^{+\infty} e^{j2\pi\eta(s-t)} \phi(\eta, \tau) x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f\tau} d\eta ds d\tau \quad (\text{II.10})$$

où $\phi(\eta, \tau)$ est une fonction bidimensionnelle appelée fonction de paramétrage ou noyau DTF qui a pour rôle le lissage des interférences dans le plan Doppler-retard (η, τ) et détermine la performance globale de la distribution générée, t et τ désignent les variables du temps, tandis que f et η sont les variables de fréquence [24].

De manière équivalente, on peut utiliser la notation du noyau temps-retard $G(t, \tau)$, exprimée comme la transformée de Fourier du noyau Doppler-retard $\phi(\eta, \tau)$ par rapport à η , c'est-à-dire [24]:

$$G(t, \tau) = \int_{-\infty}^{+\infty} \phi(\eta, \tau) e^{-j2\pi\eta t} d\eta \quad (\text{II.11})$$

de telle sorte que la classe générale des DTF quadratiques puisse être définie en termes de signal et de noyau du domaine temps-retard comme suit [24]:

$$TFD_x(t, f, G) = \iint_{-\infty}^{+\infty} G(t - s, \tau) x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f \tau} ds d\tau \quad (\text{II.12})$$

L'avantage de l'expression (II.12) est de simplifier le calcul de la DTF en réduisant le nombre d'intégrales de trois à deux, en particulier lorsque (II.11) a une forme analytique connue, comme est le cas de la PCBD définie ci-après.

II.3.3.1 Les distributions basées sur les noyaux à support compact

a. Le noyau CB Polynomial (PCB)

Le noyau de support compact PCB (Polynomial Cheriet-Belouchrani kernel) [28, 29] est dérivé de la fonction gaussienne sauf que sa forme est polynomiale. Il est exprimé dans le domaine du temps-retard comme suit :

$$G_{PCB}(t, \tau) = \begin{cases} \frac{\gamma + 1}{\pi \lambda^{2\gamma + 2}} (\lambda^2 - (t^2 - \tau^2))^\gamma & \text{si } (t^2 + \tau^2) < \lambda^2 \\ 0 & \text{ailleurs} \end{cases} \quad (\text{II.13})$$

où λ est un paramètre prédéterminé et γ est le contrôleur de la bande passante du noyau, considéré comme un entier positif de sorte que le noyau résultant a une forme polynomiale. Cette propriété est très intéressante car elle permet une extrême facilité d'ajustement de la représentation induite, ce qui fait de ce noyau le plus avantageux par rapport aux autres noyaux proposés dans la littérature ATF.

La Figure 2.9 présente les graphes du noyau PCB pour différentes valeurs du paramètre de lissage γ avec $\lambda = 2.5$. Nous remarquons à chaque fois la valeur du γ augmente, le support compact se rétrécit et par conséquent, la bande passante du noyau diminue [20].




Figure 2.9 : Le profil 2D du noyau PCB normalisé par rapport à son pic situé à l'origine ($t = 0$, $\tau = 0$) avec $\lambda = 2,5$. (a) $\gamma = 3$ et (b) $\gamma = 10$ [24].

La Figure 2.10 illustre le tracé TF de la distribution PCBD de deux signaux Doppler. Différentes valeurs de γ sont utilisées avec $\lambda = 4$. Nous remarquons à chaque fois en augmentant γ (le contrôle de la bande passante du noyau PCB), la DTF correspondante permet une meilleure élimination des interférences tout en offrant une haute résolution à la fois en temps et en fréquence.




Figure 2.10 : La PCBD de deux signaux Doppler ($\lambda = 4$). (a) $\gamma = 3$, (b) $\gamma = 9$ et (c) $\gamma = 29$ [24].

II.4 Application de l'analyse temps-fréquence à la détection des mouvements humains

La détection et la classification des activités humaines à l'aide de la technologie radar ont suscité un intérêt considérable de la part des chercheurs en raison de ses multiples avantages. Cette technologie est très intéressante dans de nombreuses applications liées à la sécurité et la surveillance, notamment dans les domaines de la santé et militaire, où la reconnaissance des activités des personnes à partir des signatures radar sont très demandées [30].

La plupart des méthodes d'analyse des signaux micro-Doppler utilisent des spectrogrammes classiques pour afficher les données dans le plan temps-fréquence (TF). Cependant, ce projet de fin d'études utilise une famille spécifique de distributions temps-fréquence quadratiques basée sur des noyaux de support compacts [28,29] pour analyser ce type de signaux de nature spectrale non-stationnaire. Plus précisément, les diagrammes TF associées aux signatures micro-Doppler examinées sont générées à l'aide de la distribution à base noyau polynomial de Cheriet-Belouchrani, le PCB, défini par (II.13). Cette représentation est choisie pour sa capacité à fournir une énergie hautement concentrée dans le plan temps-fréquence [31,32]. Cela facilite considérablement la tâche de classification. Une autre caractéristique notable de la PCB est qu'un lissage robuste peut être effectué sans fenêtre, le noyau lui-même servant de fenêtre. Il s'agit d'un inconvénient fondamental de l'utilisation des représentations TF les plus connues, telles que la distribution pseudo Wigner-Ville lissée (SPWVD) ou le spectrogramme. Dans ces cas, sélectionner la fenêtre et la longueur optimales parmi différentes options peut s'avérer assez difficile [33]. De plus, les performances globales de la PCB peuvent être ajustées en modifiant un seul paramètre entier, tandis que le calcul est considérablement réduit car la distribution est nulle en dehors du support compact [29,31,32].

La Figure 2.11 montre les diagrammes temps-fréquence générés par la PCB illustrant le mouvement d'une personne marchant et courant. La fréquence Doppler est affichée sur l'axe vertical, tandis que le temps est représenté sur l'axe horizontal. L'amplitude du signal réfléchi est indiquée par des couleurs, du bleu pour les faibles intensités au rouge pour les intensités les plus élevées. On observe une concentration significative de l'énergie autour de 200 Hz, représentée par une zone rouge foncé, caractéristique des mouvements réguliers du torse, alors que les mouvements des bras et des jambes pendant la marche génèrent des oscillations discontinues par rapport à la droite $f=200$ Hz. En comparaison, la signature micro-Doppler d'une personne qui court est nettement différente avec l'apparition d'une fréquence dominante de 600 Hz. Cette élévation

de fréquence reflète l'accélération du rythme des mouvements corporels et une plus grande vitesse de mouvement par rapport à la marche.

La Figure 2.12 représente les résultats de l'analyse temps-fréquence par la PCBD d'un groupe de personnes marchant (a) et courant (b) vers le radar. Nous remarquons l'apparition d'une composante principale bien marquée de fréquence de 200 Hz pratiquement parallèle à l'axe du temps, sans observation d'oscillations discontinues. En revanche, la course à pied génère des fréquences plus élevées jusqu'à 400 Hz en raison d'une vitesse plus importante. Nous remarquons également que l'énergie globale du signal est plus forte qu'avec une seule personne, car plusieurs individus contribuent au signal réfléchi.




Figure 2.11 : Analyse temps-fréquence par la PCBD des signatures micro-Doppler ($\lambda = 2.5$, $\gamma = 19$). (a) Une personne qui marche et (b) une personne qui court [33].




Figure 2.12 : Analyse temps-fréquence par la PCBD des signatures micro-Doppler ($\lambda = 2.5$, $\gamma = 19$). (a) Un groupe de personnes marchant et (b) un groupe de personnes courant [33].

Dans le même contexte, la Figure 2.13 représente les images temps-fréquence des signatures micro-Doppler de six activités humaines distinctes fournies par la PCBD ($\gamma=20$). Nous voyons clairement que l'analyse temps-fréquence nous permet de distinguer par simple inspection visuelle les classes sous-jacentes à ces signatures, ce qui rend la classification automatique très prometteuse. Cet aspect sera abordé au chapitre 3.




Figure 2.13 : Signatures micro-Doppler TF de six activités humaines distinctes générées par la PCBD ($\gamma=20$). (a) Marcher en avant et en arrière, (b) s'asseoir sur une chaise, (c) se lever d'une chaise, (d) se baisser pour ramasser quelque chose, (e) boire de l'eau debout, et (f) tomber frontalement.

II.5 Conclusion

La détection et la classification des mouvements humains à l'aide radar reposent sur une représentation des signaux micro-Doppler, naturellement non stationnaires. Ce chapitre a présenté les principaux outils d'analyse temps-fréquence, en distinguant les approches linéaires (comme la STFT ou la transformée en ondelettes) des approches quadratiques (comme le spectrogramme, la distribution Wigner-Ville et PCBD).

Bien que largement utilisés, les spectrogrammes présentent des limites importantes, notamment dans la sélection de la fenêtre optimale et la faible concentration énergétique des composantes. En revanche, Les distributions basées sur les noyaux à support compact et en

particulier la PCBD, se sont révélées particulièrement efficaces pour ce type de signal. Grâce à son noyau polynomial, cette distribution permet une concentration élevée de l'énergie dans le plan temps-fréquence, ce qui améliore considérablement la visibilité des signatures micro-Doppler.

Ces caractéristiques font de la PCBD un outil parfaitement adapté à notre objectif : extraire des signatures précises des activités humaines (marche, course, etc.), afin d'alimenter efficacement les algorithmes de classification automatique qui seront développés dans le chapitre suivant.

Chapitre III

Détection des mouvements humains à base des signatures micro-Doppler

III.1 Introduction

La classification des signatures micro-Doppler est une étape cruciale pour l'identification et la différenciation des types de mouvements humains, qu'ils soient isolés ou collectifs (comme un groupe de personnes en mouvement). Après la transformation des signaux par l'analyse temps-fréquence (STFT, CWT, ou PCBD), ces représentations sont exploitées pour entraîner des modèles de classification [34]. Ce chapitre présente deux approches complémentaires : l'apprentissage automatique (Machine Learning) avec le Support Vector Machine (SVM), et l'apprentissage profonds (Deep Learning) avec un réseau de neurones convolutifs (CNN).

III.2 Apprentissage automatique

L'apprentissage automatique repose sur le principe de formation de modèle à partir de données disponible afin qu'il puisse effectuer des prédictions ou des classifications sur des nouvelles données non vues auparavant. Il existe différentes méthodes d'apprentissage, notamment l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement. L'apprentissage supervisé est utilisé lorsque le modèle est entraîné sur un ensemble de données étiquetées, c'est-à-dire des données dont les classes sont connues d'avance, ce qui correspond à notre cas. Une fois le modèle entraîné, il peut être utilisé pour prédire les classes de nouvelles données non étiquetées [35].

Les algorithmes d'apprentissage pour la classification sont multiples, tels que les machines à vecteurs de support (SVM), les k plus proches voisins (KNN), Arbres de décision (Decision Trees), ainsi que d'autres. Nous nous concentrerons sur SVM dans notre étude.

III.2.1 Support Vector Machine (SVM)

Le Support Vector Machine (SVM) est une méthode d'apprentissage supervisé largement utilisée pour résoudre des problèmes de classification. Son principe de base est de trouver un hyperplan qui sépare les différentes classes de données avec la plus grande marge possible. Cette marge est définie comme la distance entre l'hyperplan et les échantillons de données les plus proches, appelés vecteurs de support [36].

Dans le cas d'une classification binaire (deux classes), le SVM cherche un seul hyperplan optimal permettant de séparer les deux catégories en maximisant la marge entre elles [37].

C'est dans ce cadre que s'inscrit notre étude, où nous utilisons un SVM pour classifier des images micro-Doppler humaines issues des signaux radar, en distinguant deux types de mouvements : marche (walking) et course (running).

Les images générées par PCBD sont utilisées pour entraîner les modèles de classification après une extraction de caractéristiques à l'aide de descripteurs manuellement définis. Le SVM apprend à différencier ces deux classes de mouvements à partir des informations dans les images, en construisant un hyperplan de séparation optimal

L'équation générale d'un hyperplan utilisé par le SVM est donnée par :

$$\omega^T x + b = 0 \quad (\text{III.1})$$

où :

ω est le vecteur des poids qui définit l'orientation de l'hyperplan.

x est le vecteur des caractéristiques représentant un échantillon.

b est un biais qui ajuste la position de l'hyperplan.

III.3 Apprentissage profond

L'apprentissage profond (ou deep learning) est une méthode d'intelligence artificielle qui utilise des réseaux de neurones avec plusieurs couches pour apprendre des informations complexes à partir de grandes quantités de données. Ces modèles peuvent automatiquement détecter des caractéristiques importantes dans les données, ce qui leur permet d'effectuer des tâches comme la classification d'images, la reconnaissance vocale, ou la traduction automatique, souvent avec de meilleurs résultats que les méthodes classiques [38].

Les réseaux de neurones utilisés en apprentissage profond incluent des types comme les réseaux convolutifs (CNN) pour les images ou les réseaux récurrents (RNN) pour les données temporelles, permettant ainsi de résoudre divers problèmes [38].

III.3.1 Réseaux de Neurones Convolutifs (CNN)

Les réseaux de neurones convolutifs (ou *Convolutional Neural Networks*, CNN) sont un type spécial de réseau de neurones utilisés principalement pour traiter des données sous forme d'images. Contrairement aux réseaux classiques, les CNN sont capables d'extraire automatiquement des caractéristiques importantes (comme les bords, les textures ou les formes) à partir des images, sans qu'il soit nécessaire de les définir manuellement [38].

Un CNN est composé de plusieurs types de couches comme montre la Figure 3.1 :

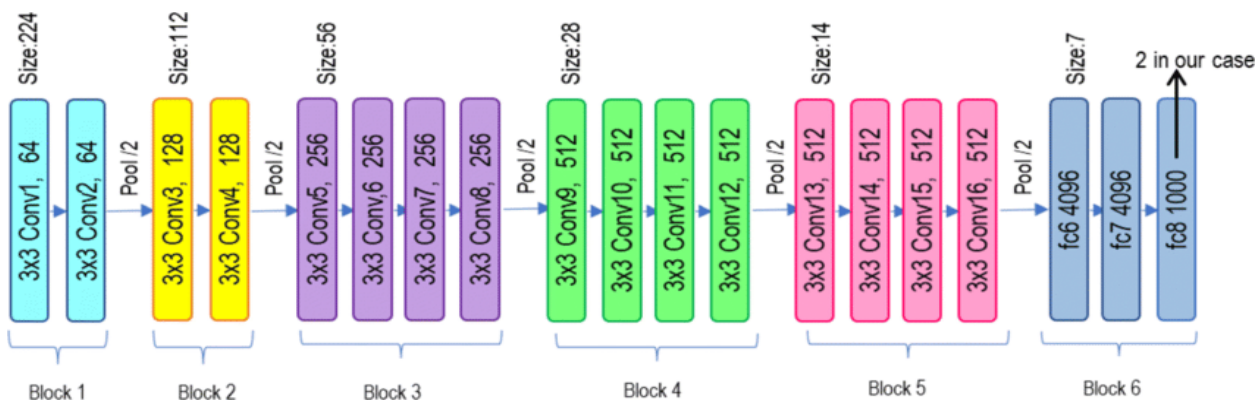


Figure 3.3 : Architecture de VGG19 [41].

Les Figures 3.4 et 3.5 représentent les architectures de DenseNet201 et ResNet50, respectivement.

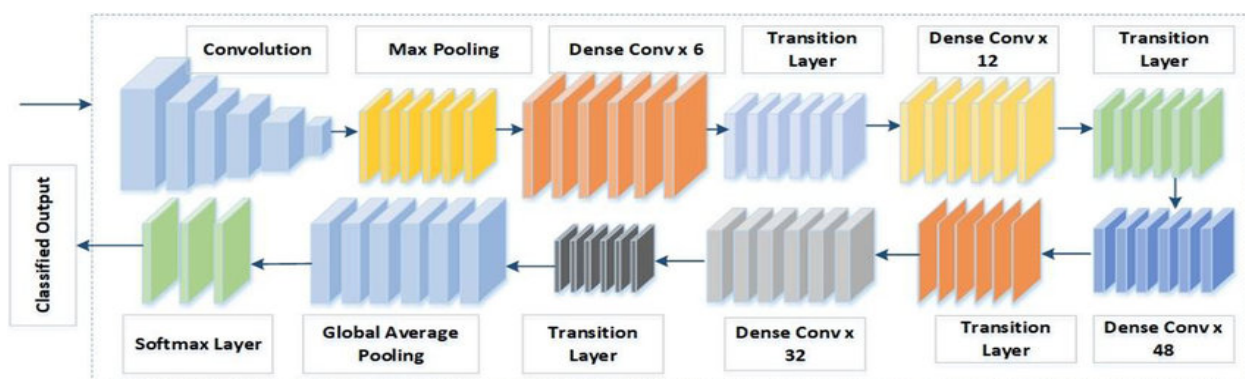


Figure 3.4 : Architecture de DenseNet201 [42].

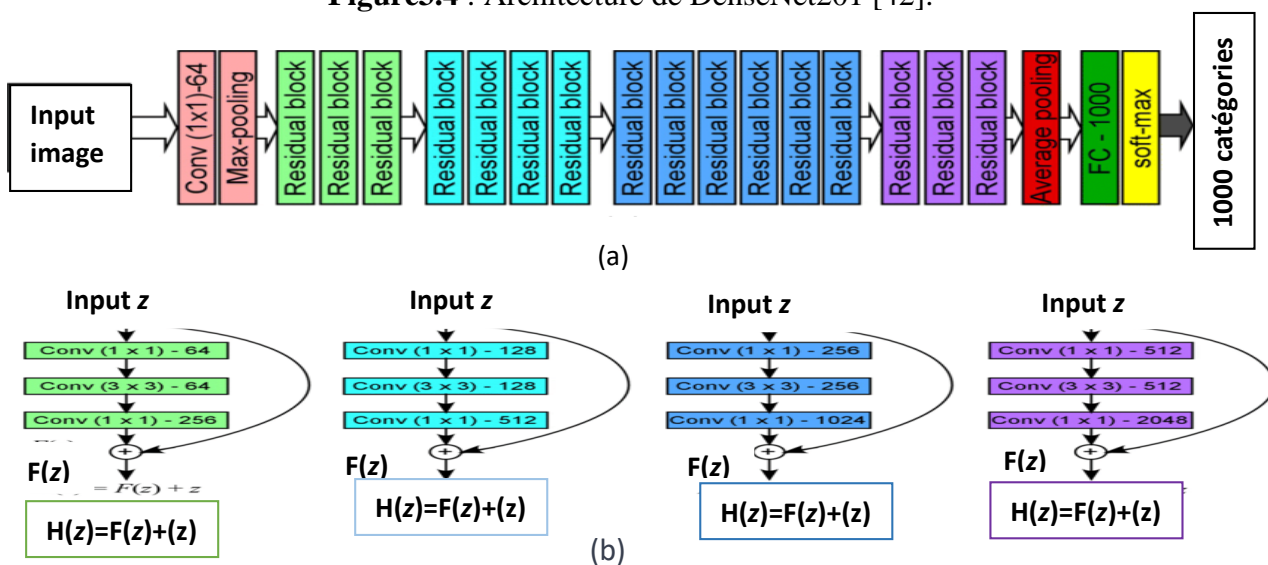


Figure 3.5 : Architecture de ResNet50 (a) Architecture globale (b) Architecture de chaque bloc résiduel [43].

III.4 Implémentation pratique et résultats

III.4.1 Description de base de données

La base de données utilisée dans cette étude a été constituée à partir des signaux radar captés par un radar Doppler pulsé de surveillance terrestre. Cette base de données est librement accessible en téléchargement à l'adresse suivante [44]. Le Tableau 3.1 et la Figure 3.6 présentent les principales caractéristiques du système radar et de la base de données.

Tableau 3.1 : Caractéristiques techniques du radar et description de la base de données utilisée

Catégorie	Détails
Type de radar	Radar pulsé-Doppler de surveillance terrestre
Fréquence du radar	16,8 GHz
Puissance moyenne	5 Mw
Largeur d'impulsion	15 μ s
Résolution en portée	150 m
Résolution en élévation	7,5°
Résolution en azimut	5°
Fréquence d'échantillonnage	4 kHz
Durée d'enregistrement par scénario	\geq 20 secondes
Outil de traitement	MATLAB
Types de cibles	Personnes seules et groupes de personnes
Types de mouvements	Rampant, marche, course (Crawling, Walking, Running)
Directions des mouvements	Éloignement ou rapprochement du radar (Go-away, Toward)

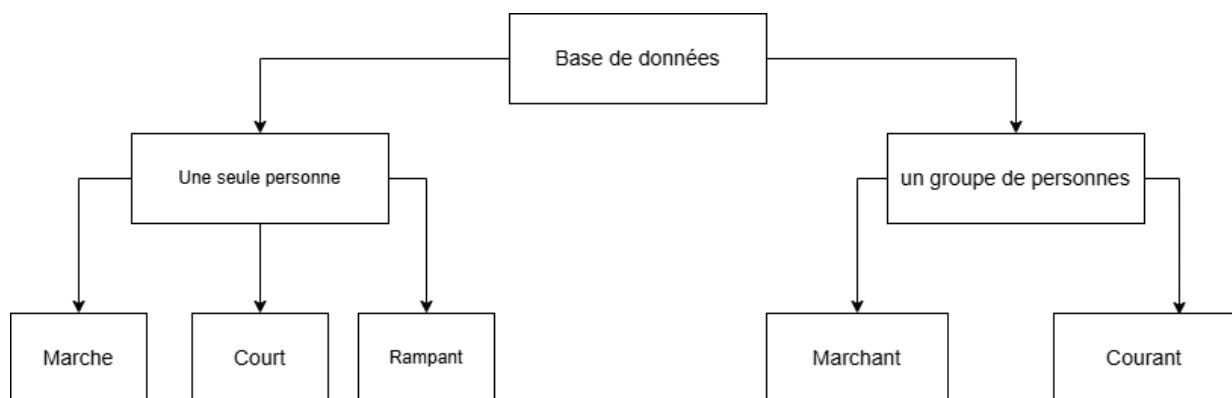


Figure 3.6 : Description de la base de données.

Dans cette étude, nous nous concentrons sur la classification de deux types de mouvements humains individuels : la marche et la course. Les signatures micro-Doppler issues de ces mouvements sont transformées en images temps-fréquence par la distribution PCBD, puis utilisées comme entrées pour les modèles de classification. Le nombre d'images résultantes pour les classes Marchant et Courant est respectivement de 99 et 71.

La Figure 3.7 représente le schéma fonctionnel des modèles appliqués aux images PCBD générées.

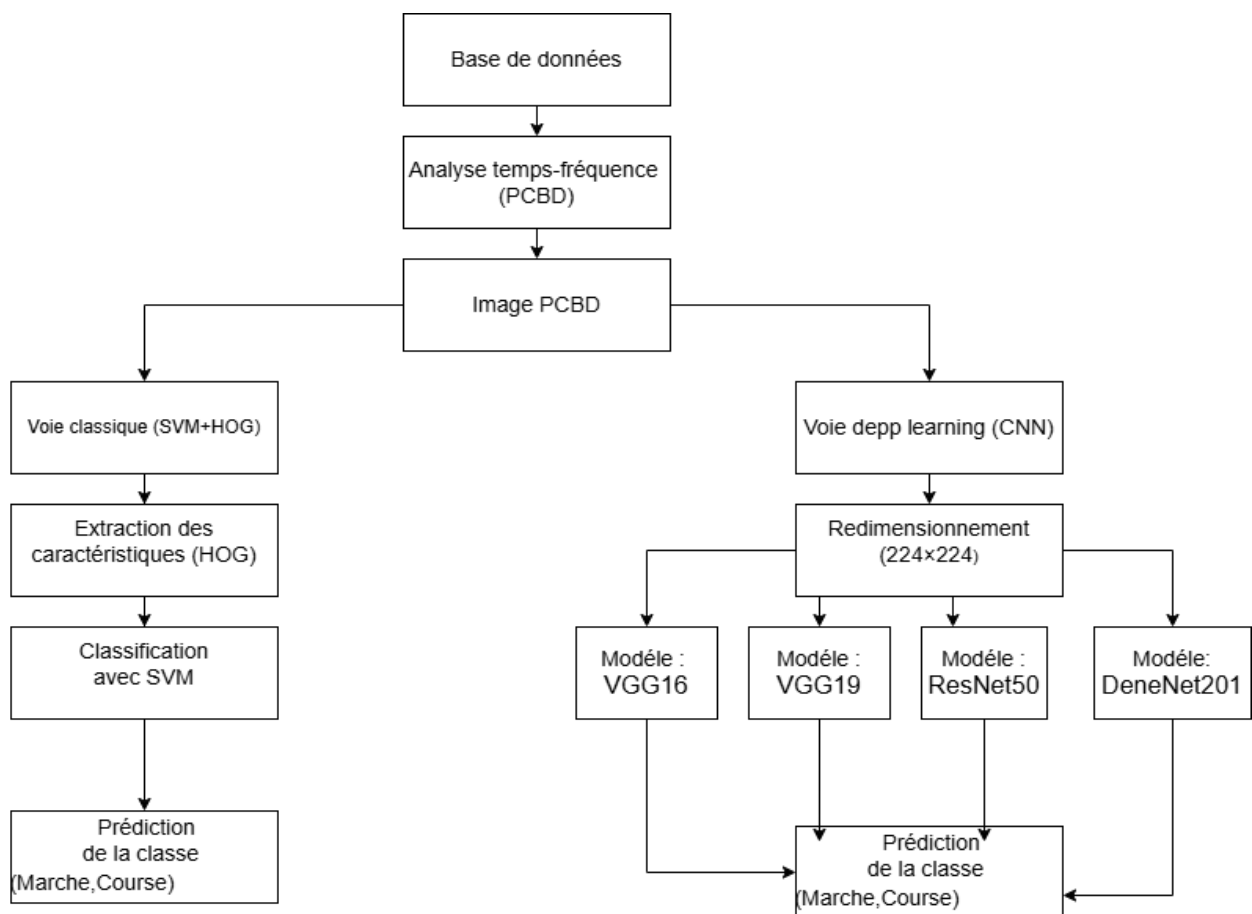


Figure 3.7 : Schéma fonctionnel des méthodes de traitement appliquées aux images TF des mouvements humains.

III.4.2 Classification avec SVM

Le Support Vector Machine (SVM) est une méthode d'apprentissage supervisé utilisé pour la classification, qui cherche à séparer les données en maximisant la marge entre les classes. Dans

Cette étude nous avons utilisé un classifieur SVM après une phase d'extraction des caractéristiques par méthodes classiques appliquées aux images PCBD. Pour cela, nous avons

utilisé le descripteur HOG (Histogram of Oriented Gradients), qui permet de capturer la structure locale des motifs dans l'image.

Le schéma de la Figure 3.8 illustre les étapes de cette chaîne de traitement.

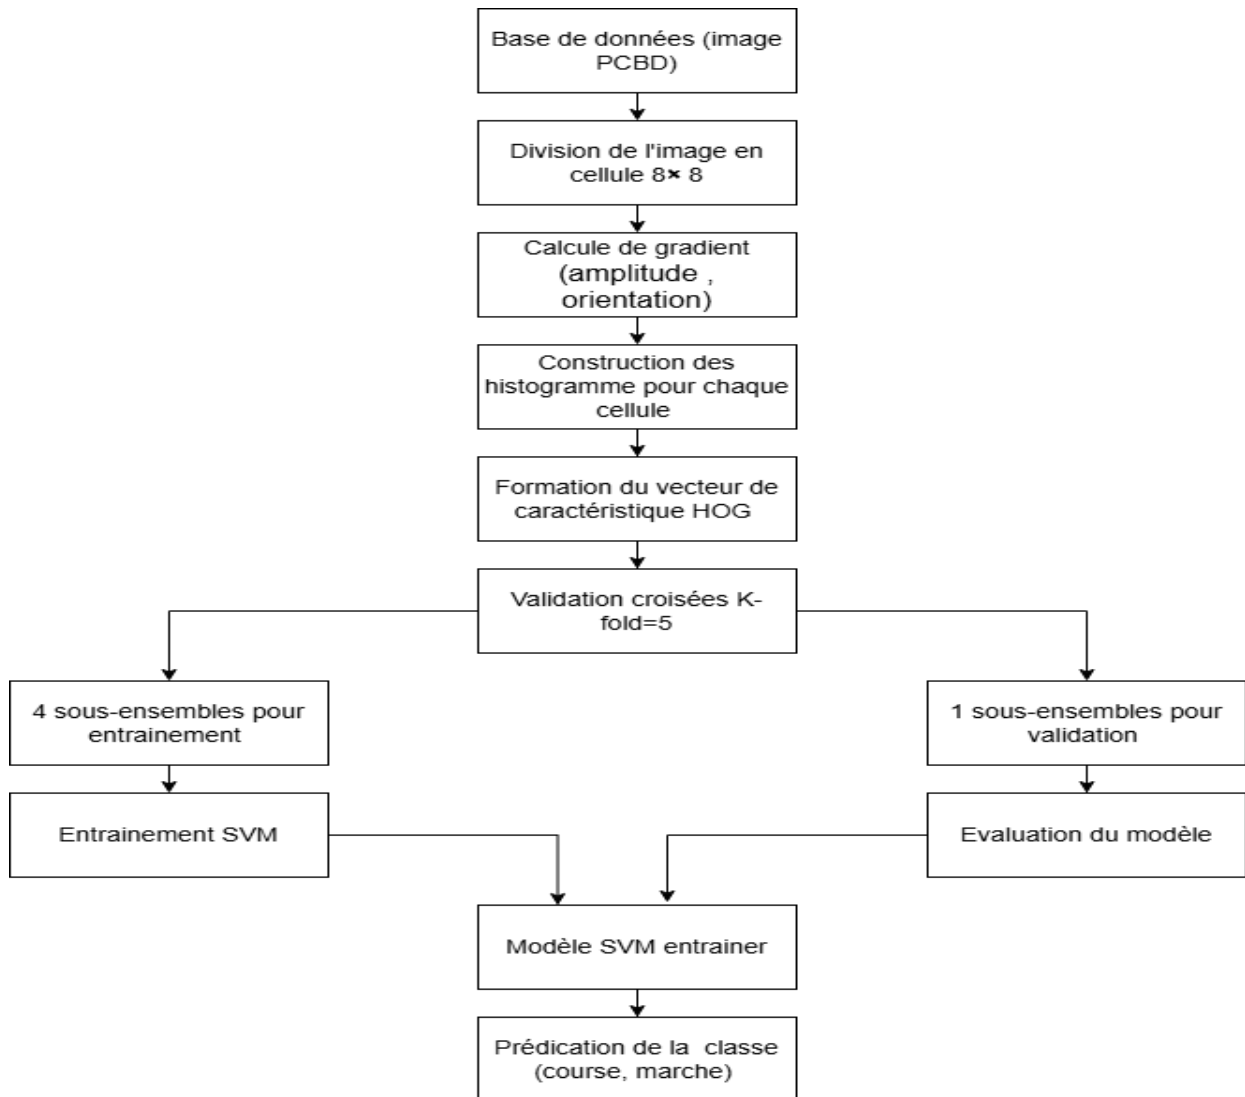


Figure 3.8 : Schéma détaillé de classification par SVM des images TF après extraction des caractéristiques HOG.

III.4.3 Classification avec CNN

Pour l'approche par apprentissage profond, nous avons utilisé des modèles CNN pré-entraînés (VGG16, VGG19, ResNet50 et DenseNet201) dans une stratégie de transfert Learning.

Comme ces réseaux profonds comportent un nombre élevé de paramètres, leur entraînement direct sur de petits ensembles de données s'avère difficile et les expose fortement au

sur-apprentissage. Une méthode couramment utilisée pour résoudre ce problème est le réglage fin (*fine-tuning*) avec des réseaux pré-entraînés. En effectuant un réglage fin d'un réseau pré-entraîné, le modèle peut tirer parti des représentations apprises à partir du plus grand ensemble de données, améliorant ainsi ses performances sur le petit ensemble de données [45].

A cet égard, les modèles employés sont d'abord entraînés sur de grandes bases d'images (ImageNet). La dernière couche est ensuite remplacée par deux neurones avec une fonction d'activation softmax afin d'adapter les modèles à notre tâche de classification binaire (marche/course).

L'erreur de classification a été calculée à l'aide de la fonction de perte d'entropie croisée, définie comme suit [46] :

$$Perte = -\sum_{i=1}^n y_i \log(\hat{y}) \quad (\text{III.2})$$

Où y_i représente le label réel pour la classe et \hat{y} désigne la probabilité prédite pour la classe, obtenue en sortie de la fonction softmax.

L'implémentation a été réalisée en Python, dans l'environnement de développement Visual Studio Code, à l'aide de l'extension Jupyter. L'utilisation d'un notebook Jupyter permet une exécution par bloc, ce qui facilite le débogage et l'implémentation du code. Le processus de traitement est illustré par la Figure 3.9.

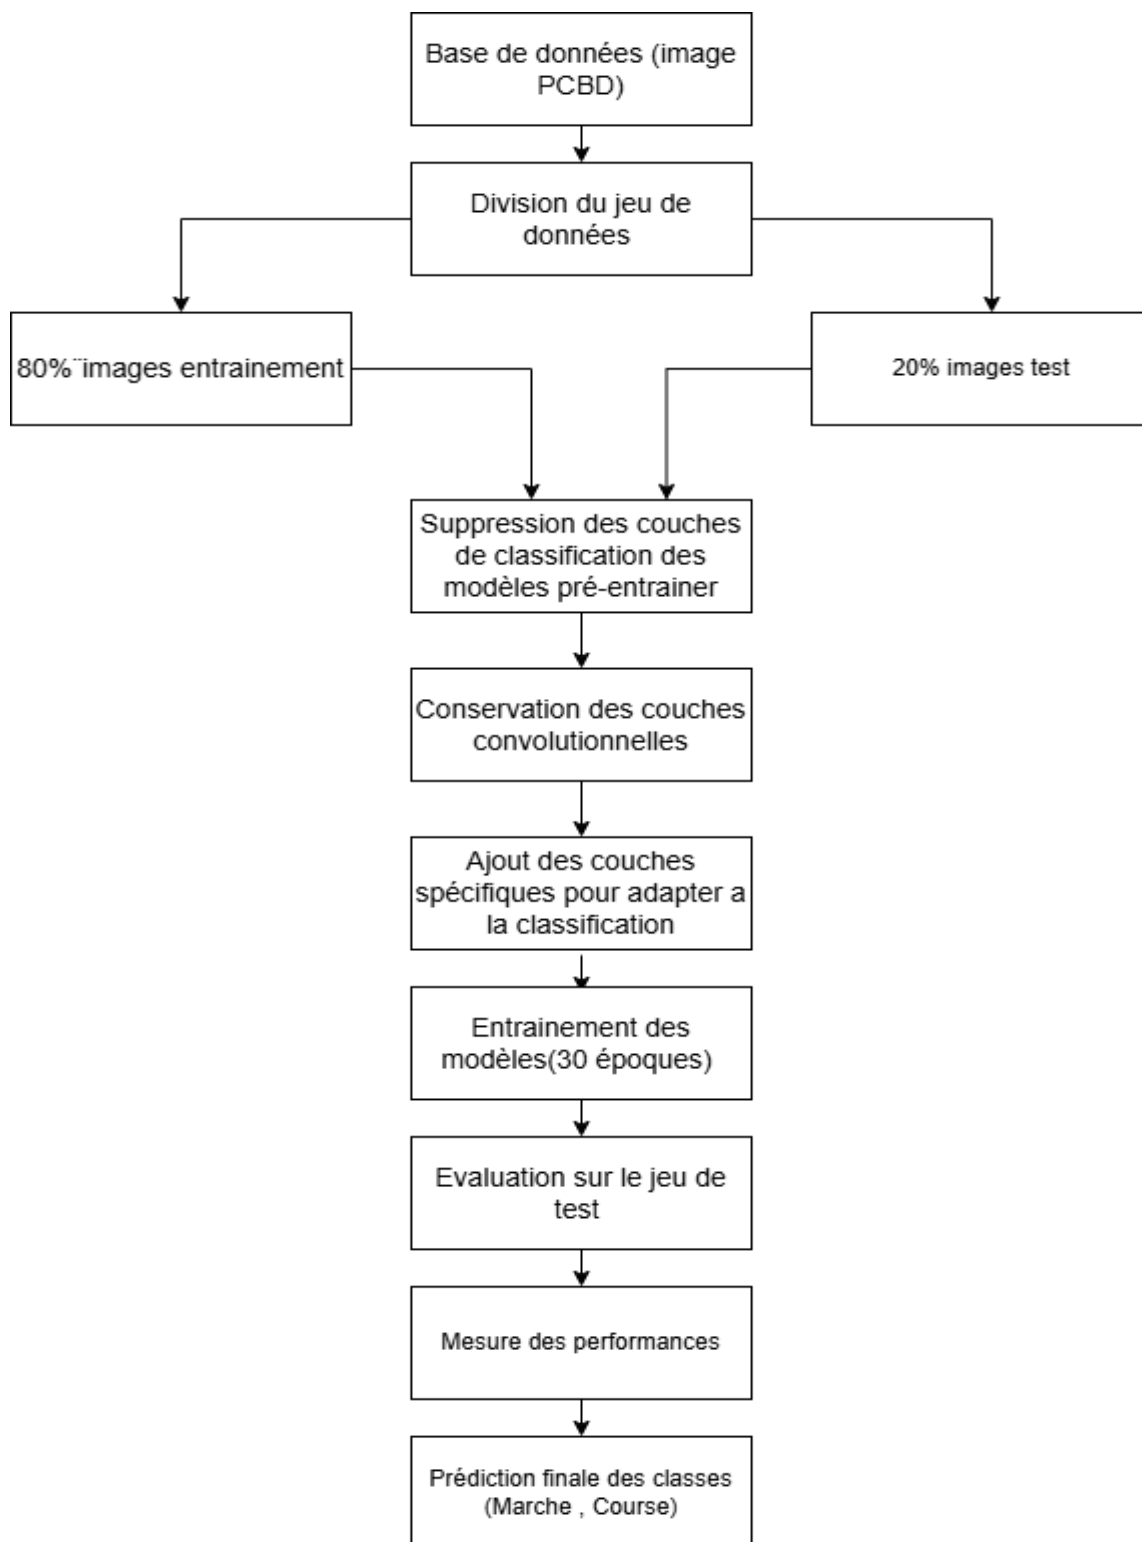


Figure 3.9: Schéma détaillé de classification CNN des images TF générées par la PCBD dans le cadre de transfert learning.

III.4.4 Les métriques de performance

Pour évaluer les performances des modèles de classification, nous utilisons les métriques exactitude (accuracy), précision, rappel (recall) et F1-score. Leurs formules présentées dans le Tableau 3.2.

Tableau 3.2 : Les métriques de performance utilisées pour évaluation et comparaison.

Métrique	Formule
Exactitude	$(VP+VN)/(VP+VN+FP+FN)$
Précision	$VP/(VP+FP)$
Rappel	$VP/(VP+FN)$
F1-score	$2 \times (\text{Précision} \times \text{Rappel})/(\text{Précision} + \text{Rappel})$

où :

VP = Vrai Positif (True Positive).

VN = Vrai Négatif (True Negative).

FP = Faux Positif (False Positive).

FN = Faux Négatif (False Negative)

L'exactitude mesure le pourcentage de prédictions correctes globales. La précision indique combien de prédictions positives sont réellement correctes, tandis que le rappel mesure la capacité du modèle à identifier toutes les instances positives. Le F1-score combine précision et rappel pour offrir une vue équilibrée, surtout en cas de classes déséquilibrées.

III.4.5 Résultats obtenus

Les résultats expérimentaux obtenus, pour les CNN, les performances sont exprimées en termes d'exactitude, de précision, rappel et F1-score. Concernant le modèle SVM, seule l'exactitude sur les phases d'entraînement et de validation a été mesurée.

En outre, afin d'évaluer l'efficacité en temps réel de chaque modèle, le temps d'inférence a été mesuré. Il s'agit du délai nécessaire à un modèle pour analyser une image et produire une prédiction. L'expérimentation a été réalisée sur une machine équipée d'un processeur Intel Core i9 (12^e génération), de 32 Go de mémoire RAM, d'un GPU NVIDIA RTX 3080 Ti, avec TensorFlow GPU version 2.15 et Python 3.10.12.

Le Tableau 3.3 présente les performances obtenues pour chaque modèle.

Tableau 3.3: Les performances des modèles (SVM, VGG16, VGG19, ResNet50, DenseNet201).

Modèle	Extraction	Validation	Exactitude	Précision	Recall	F1_score
SVM	HOG	5-plis	98.82%	-	-	-
CNN-ResNet50	Automatique	Hold out 80/20	100%	100%	100%	100%
CNN-VGG16	Automatique	Hold out 80/20	100%	100%	100%	100%
CNN-VGG19	Automatique	Hold out 80/20	100%	100%	100%	100%
CNN-DenseNet201	Automatique	Hold out 80/20	100%	100%	100%	100%

On observe que le modèle SVM atteint une exactitude de 98,82 % en utilisant la validation croisée à 5 plis. En revanche, tous les modèles CNN, à savoir VGG16, VGG19, ResNet50, et DenseNet201, obtiennent 100 % pour l'exactitude, précision, rappel et F1-score lorsqu'ils sont testés sur les 20 % de l'ensemble de données réservé au test. Cette différence s'explique par le fait que le SVM repose sur une extraction manuelle des caractéristiques (HOG), tandis que les CNN extraient automatiquement des caractéristiques plus complexes.

Le Tableau 3.4 détaille le temps d'entraînement et le temps d'inférence par image pour chaque modèle de deep learning :

Tableau 3.4 : Le temps d'entraînement et le temps inférence de chaque modèle.

Modèle	Temps entrainement	Temps inférence d'une image
VGG16	18.58 sec	0.029 sec
VGG19	29.29 sec	0 .034 sec
ResNet50	27.97 sec	0.030 sec
DenseNet201	66 .10 sec	0.040 sec

On observe que VGG16 est le modèle le plus rapide à entraîner (18,58 secondes) et possède également le temps d'inférence le plus court (0,029 seconde), ce qui le rend adapté aux systèmes nécessitant une exécution rapide mais disposant de ressources limitées. En comparaison, VGG19 demande un temps d'entraînement plus long (29,29 secondes) et un temps d'inférence légèrement supérieur à VGG16, en raison de sa profondeur plus importante.

Le modèle DenseNet201 présente à la fois le temps d'entraînement le plus long (66,10 secondes) et le temps d'inférence le plus élevé (0,040 seconde). Cette complexité s'explique par sa structure dense, qui accroît considérablement la quantité de calculs nécessaires.

Enfin, ResNet50 se distingue par un bon compromis entre performance et efficacité, avec un temps d'entraînement modéré (27,97 secondes) et un temps d'inférence raisonnable (0,030 seconde), tout en maintenant une très bonne capacité de généralisation.

III.4.6 Graphiques de performance :




Figure 3.10 : Exactitude d'entraînement et de Validation par SVM en fonction du nombre de plis k en validation croisée.

Les Figures 3.11 et 3.12 présentent les courbes d'évolution de l'exactitude et de la fonction de perte durant l'entraînement et la validation du modèle VGG16.




Figure 3.11 : Courbe d'exactitude d'entraînement et de validation en fonction du nombre d'époques pour le modèle VGG16.




Figure 3.12: Courbes de perte d'entraînement et de validation en fonction du nombre d'époques pour le modèle VGG16.

On observe que le modèle VGG16 converge dès la 10^{ème} époque en termes de précision, avec une diminution significative de la fonction de perte dès la 4^{ème} époque. Cette rapidité de convergence s'explique par l'architecture simple de VGG16.

L'évolution de la précision et de la fonction de perte du modèle VGG19, observée durant l'entraînement et la validation, est représentée dans les Figures 3.13 et 3.14.




Figure 3.13 : Courbe d’exactitude d’entraînement et de validation en fonction du nombre d’époque pour le modèle VGG19.




Figure 3.14 : Courbes de perte d’entraînement et de validation en fonction du nombre d’époques pour le modèle VGG19.

Nous remarquons que le modèle VGG19 converge en précision à partir de la 15^e époque, avec une diminution notable de la fonction de perte dès la 3^e époque. Cette progression est liée à son architecture plus profonde que celle de VGG16, contrairement à d’autres architectures comme ResNet50, VGG19 ne bénéficie pas de blocs résiduels, ce qui peut ralentir la convergence.

Les courbes d’évolution de la précision et de la fonction de perte du modèle DenseNet50, pendant l’entraînement et la validation, sont présentées dans les Figures 3.15 et 3.16.




Figure 3.15 : Courbe d'exactitude d'entraînement et de validation en fonction du nombre d'époque pour le modèle DenseNet201.




Figure 3.16 : Courbes de perte d'entraînement et de validation en fonction du nombre d'époques pour le modèle DenseNet201.

Concernant le modèle DenseNet201, nous remarquons une convergence plus rapide que VGG16 et VGG19, avec une stabilisation de la précision dès la 5^e époque. La fonction de perte atteint zéro à cette même époque. De plus, une stabilité de la courbe de validation est observée dès la 13^e époque. Cette performance grâce à la densité élevée de connexions dense entre les couches.

Les figures 3.17 et 3.18 illustrent l'évolution de la précision et de la fonction de perte au cours de l'apprentissage et de la validation du modèle ResNet50.




Figure 3.17 : Courbes d'exactitude d'entraînement et de validation en fonction du nombre d'époques pour le modèle ResNet50.




Figure 3.18 : Courbes de perte d'entraînement et de validation en fonction du nombre d'époques pour le modèle ResNet50.

Le modèle ResNet50 se distingue par une convergence extrêmement rapide comparée aux autres modèles. Il atteint une précision stable dès la 2ème époque, et sa fonction de perte chute pratiquement à zéro dès cette même époque. Cette rapidité d'apprentissage, malgré une architecture complexe, s'explique par l'utilisation de blocs résiduels, qui facilitent la circulation des gradients et permettent un entraînement plus efficace même en profondeur.

Le Tableau 3.5 représentant la matrice de confusion du modèle CNN, utilisée pour évaluer sa capacité à distinguer les mouvements de marche (*walking*) et de course (*running*). On observe que le modèle a correctement prédit les 7 cas de la classe *walking* ainsi que les 10 cas de la classe *running*, sans enregistrer aucune erreur de la classification. Ces résultats indiquent que le modèle

généralise efficacement sur les données de test, démontrant ainsi une excellente performance dans la distinction des deux types de mouvement

Tableau 3.5 : Matrice de confusion des modèles CNN.

	Prédit : Walking	Prédit : Running
Réel : Walking	7	0
Réel : Running	0	10

III.4.6 Discussion

Dans cette étude, les résultats obtenus permettent de comparer les différents modèles, Le SVM, avec son extraction manuelle des caractéristiques (HOG), offre de bonnes performances, mais reste limité par rapport CNN qui extraient automatiquement des caractéristiques. Parmi les CNN, VGG16 se distingue par sa rapidité d'entraînement et d'inférence, adapté aux systèmes nécessitant des réponses rapides, bien qu'il soit limité en termes de ressources, tandis que VGG19, plus profond, présente une convergence plus lente et un temps d'entraînement et d'inférence grand grâce à son architecture profonde.

DenseNet201 converge rapidement, mais son temps d'entraînement et d'inférence est élevé en raison de sa structure dense.

Enfin, ResNet50 s'impose comme le meilleur compromis grâce à sa vitesse de convergence très rapide, ses temps d'entraînement et d'inférence raisonnables, et sa performance optimale, notamment grâce à ses blocs résiduels qui facilitent l'apprentissage profond. ResNet50 est particulièrement recommandé pour les applications en temps réel où rapidité et précision sont essentielles.

III.5 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 d'évaluer l'efficacité des méthodes d'apprentissage automatique et d'apprentissage profond dans la reconnaissance de différents types de mouvements, tels que la marche et la course.

Nous avons d'abord implémenté un classifieur SVM basé sur des caractéristiques extraites à l'aide de descripteurs HOG. Cependant, cette approche a montré des performances limitées en raison de sa dépendance cruciale à la qualité des caractéristiques manuellement extraites.

Nous avons ensuite étudié plusieurs architectures de réseaux de neurones convolutifs (CNN), notamment VGG16, VGG19, DenseNet201 et ResNet50, pré-entraînées sur ImageNet, puis adaptées à notre problème spécifique de classification des signatures micro-Doppler.

Ces architectures CNN ont démontré un potentiel particulièrement intéressant pour les applications en temps réel comme la surveillance médicale et la sécurité militaire. Ces cas d'usage nécessitent des modèles à la fois rapides, précis et robustes. Nous avons comparé les architectures en termes de vitesse de convergence lors de l'apprentissage et de temps d'inférence et d'entraînement. Nous avons conclu que ResNet50 constitue le modèle le plus adapté aux applications en temps réel, comme l'exige notre cahier de charge, en raison de sa rapidité de convergence ainsi que de ses temps d'entraînement et d'inférence raisonnables. Cette efficacité s'explique notamment par l'utilisation de blocs résiduels, qui permettent de compenser la complexité de son architecture.

Conclusions et Recommandations pour les Projets Futurs

a. Conclusions

Dans le contexte de l'analyse des signaux radar, ce projet explore des techniques de traitement du signal avancées visant à extraire des caractéristiques discriminantes à partir des signaux radar. Pour ce faire, il s'appuie sur l'analyse temps-fréquence de ces signaux, des approches d'apprentissage automatique et d'apprentissage profond, combinées à des algorithmes de classification supervisée. Étant donné que les classes de signaux sont connues à l'avance, l'objectif principal est de prédire correctement la classe de chaque signal, en fonction du type de micromouvement humain qu'il représente.

L'étude s'appuie sur un ensemble de signaux collectés à l'aide d'un radar de surveillance, correspondant aux mouvements de marche et de course d'une personne et de groupes de personnes. Les micromouvements engendrés par le déplacement des différentes parties du corps humain (torse, bras et jambes) produisent des signaux non-stationnaires, appelés signaux micro-Doppler. L'analyse de ce type de signaux nécessite une approche bidimensionnelle, telle que les représentations temps-fréquence notamment les distributions TF quadratiques.

Dans notre projet, nous avons analysé les avantages et les inconvénients des différentes techniques d'analyse temps-fréquence. La méthode PCBD a été retenue en raison de ses très hautes performances en termes de résolution, de concentration, et de suppression des termes croisés, ce qui permet la représentation la plus fidèle des lois fréquentielles des signaux micro-Doppler. De plus, comme le noyau PCB est de forme polynomiale, le paramètre de lissage unique est un entier, ce qui facilite la paramétrisation et l'optimisation de la distribution générée. Cette dernière se caractérise par un coût de calcul très faible puisque le noyau est de support compact et s'annule

Conclusions et Recommandations pour les Projets Futurs

donc lui-même en dehors d'un ensemble bien défini, ce qui réduit le nombre de points nécessitant un calcul. Toutes ces caractéristiques font de la PCBD la plus adaptée à notre application qui requiert une capacité de détection en temps-réel.

À partir des résultats d'analyse, nous nous sommes appuyés sur les caractéristiques distinctives observées entre les deux classes Courant et Marchant. Ces observations permettent ainsi de définir une signature propre à chaque classe.

Par la suite, les représentations TF générées par PCBD sont exportées en images RVB, puis utilisées comme entrées pour les modèles de classification réalisée à l'aide de techniques d'apprentissage automatique, notamment avec le classificateur SVM, ainsi qu'à l'aide de méthodes d'apprentissage profond en exploitant plusieurs architectures CNN telles que VGG16, VGG19, ResNet50, et DenseNet201. Le SVM présente certaines limites en termes de capacité de généralisation comparé aux réseaux profonds. Pour permettre une évaluation objective, nous avons comparé les modèles CNN selon plusieurs critères essentiels, à savoir : le temps d'entraînement, la vitesse de convergence, ainsi que le temps d'inférence. Ces paramètres sont particulièrement importants dans le contexte d'applications en temps réel, où la rapidité et l'efficacité du système sont cruciales. Les résultats numériques obtenus montrent que le modèle ResNet50 se distingue comme le plus adapté aux applications en temps réel parmi l'ensemble des modèles étudiés, en raison de sa rapidité de convergence ainsi que de ses temps d'entraînement et d'inférence raisonnables.

b. Recommandations pour les projets futurs

Les perspectives de développement de ce projet de fin d'études sont prometteuses. Nous proposons ce qui suit :

- L'exploration de nouvelles distributions temps-fréquence basées sur les noyaux à support compact, à savoir la version SCBD utilisant un noyau séparable permettant un lissage indépendant en temps et en fréquence,
- La classification avec d'autres architectures CNN récentes, notamment ConvNeXt V2 et MobileNet V4,
- La classification sur trois classes présentes dans la base de données actuelle (walking, running, crawling),

Conclusions et Recommandations pour les Projets Futurs

- L'exploration de nouvelles bases de données comprenant plusieurs classes et destinées à diverses applications afin d'examiner la robustesse de l'analyse temps-fréquence effectuée et des réseaux CNN utilisés, évaluant ainsi leur capacité de généralisation.

Bibliographie

- [1] Twersky, V. (1964). Rayleigh scattering. *Applied Optics*, 3(10), 1150–1162. <https://doi.org/10.1364/AO.3.001150>
- [2] Skolnik, M. I. (2001). *Introduction au radar* (2^e éd.). Artech House.
- [3] Lycée Saint-Exupéry de Mantes-la-Jolie. (2012, 23 octobre). *L'effet Doppler* [PDF]. Académie de Versailles. https://phychim.ac-versailles.fr/IMG/pdf/dossier_doppler.
- [4] forocoches. (s.d.). *Flashan los radares en los dos sentidos* forocoches. <https://forocoches.com/foro/showthread.php?t=9877247>
- [5] EscuelaPedia. (s.d.). *Hippolyte Fizeau* [Photographie]. EscuelaPedia. <https://www.escuelapedia.com/wp-content/uploads/Hippolyte-Fizeau.jpg>
- [6] Perrin, S. (2022, 6 juillet). *L'effet Doppler : définition, principe et formules*. AuFutur. <https://aufutur.fr/revisions/physique-chimie/effet-doppler-definition-principe-formules/>
- [7] SlidePlayer. (n.d.). *Slide 4 d'une présentation PowerPoint* [Diapositive]. https://images.slideplayer.fr/18/5904916/slides/slide_4.jpg
- [8] Shopify. (2023, septembre 22). *Capture d'écran d'une interface utilisateur* [Image]. https://cdn.shopify.com/s/files/1/0093/2298/7617/files/Screenshot_2023-09-22_at_11.21.55_AM.png?v=1695345729
- [9] Université de Limoges. (2018). *Mémoire : Étude de l'effet Doppler dans le domaine médical* (M-MMEEFPC-2018-01). Aurore - Université de Limoges. <https://aurore.unilim.fr/memoires/nxfile/default/d8439aff-9bee-4bf0-a02b-afea5f448a5a/blobholder:0/M-MMEEFPC-2018-01.pdf>
- [10] La Rédaction. (2023, 24 novembre). *Utiliser l'effet Doppler en médecine : applications et avantages*. Umvie. <https://umvie.com/utiliser-leffet-doppler-en-medecine-applications-et-avantages/>
- [11] Fidelio. (s.d.). *Points essentiels* [Présentation PowerPoint]. SlideServe. <https://www.slideserve.com/fidelio/points-essentiels-powerpoint-ppt-presentatio>
- [12] Skolnik, M. I. (2008). *Radar handbook* (3rd ed.). McGraw-Hill Education.

- [13] Fidelio. (s.d.). *Points essentiels [Présentation PowerPoint]*. SlideServe. <https://www.slideserve.com/fidelio/points-essentiels-powerpoint-ppt-presentatio>
- [14] Le Dauphiné. (2021, 23 novembre). *Les radars flashent-ils dans les deux sens* Le Dauphiné. <https://www.ledauphine.com/magazine-automobile/2021/11/23/les-radars-flashent-ils-dans-les-deux-sens>
- [15] ResearchGate. (s.d.). *Réseau de recherche scientifique*. ResearchGate. <https://www.researchgate.net/>
- [16] MathWorks. (s.d.). *Introduction to micro-Doppler effects*. MathWorks Radar Toolbox. <https://www.mathworks.com/help/radar/ug/introduction-to-micro-doppler-effects.html>
- [17] Université de Limoges. (s.d.). *Portail Aurore – Mémoire universitaire*. Aurore - Université de Limoges. <https://aurore.unilim.fr>
- [18] Boashash, B. (2016). *Time–Frequency Signal Analysis*. In *Time-Frequency Signal Analysis and Processing: A Comprehensive Reference* (2nd ed., pp. 1–3). Academic Press.
- [19] Gabor, D. (1946). Theory of communication. *Journal of the Institution of Electrical Engineers - Part III: Radio and Communication Engineering*, 93(3), 429–457.
- [20] Seninete, S. (2020). *Practical estimation of real-life signals' energy using time-frequency distributions derived from kernels with compact support (KCS)* (Doctoral dissertation). Université de Bejaïa, Faculté des Sciences et de la Technologie, Département de Génie Électrique.
- [21] Mallat, S. (1999). *A wavelet tour of signal processing*. Academic Press.
- [22] Wigner, E. P. (1932). On the quantum correction for thermodynamic equilibrium. *Physical Review*, 40, 749–759.
- [23] Ville, J. (1948). Théorie et applications de la notion de signal analytique. *Câbles et Transmission*, 2A, 61–74.
- [24] Abed, M. (2015). *Time-Frequency Distributions: Compact Support Kernels, Performances and Implementations* (Doctoral dissertation). École Nationale Polytechnique.
- [25] Hlawatsch, F., & Boudreaux-Bartels, G. F. (1992). Linear and quadratic time-frequency signal representations. *IEEE Signal Processing Magazine*, 9(2), 21–67.
- [26] Velez, E. F., & Absher, R. G. (1989, May). Transient analysis of speech signal using the Wigner time frequency representation. In *ICASSP-89. International Conference on Acoustics, Speech, and Signal Processing*, Glasgow, Scotland.
- [27] Cohen, L. (1989). Time-frequency distributions—a review. *Proceedings of the IEEE*, 77(7), 941–981.

- [28] Abed, M., Belouchrani, A., Cheriet, M., & Boashash, B. (2012). Time-frequency distributions based on compact support kernels: Properties and performance evaluation. *IEEE Transactions on Signal Processing*, 60(6), 2814–2827.
- [29] Abed, M., & Belouchrani, A. (2018). Performance analysis and computational cost evaluation of high-resolution time-frequency distributions derived from compact support time-lag kernels. *Digital Signal Processing*, 78, 1–19.
- [30] Chakraborty, M., Kumawat, H. C., Dhavale, S. V., & Raj, A. A. B. (2022). DIAT- μ RadHAR (Micro-Doppler Signature Dataset) & μ RadNet (A Lightweight DCNN)—For human suspicious activity recognition. *IEEE Sensors Journal*, 22(7), 6851–6858. <https://doi.org/10.1109/JSEN.2022.3151943>
- [31] Adoul, A., Abed, M., & Belouchrani, A. (2022). Time-frequency readability enhancement of compact support kernel-based distributions using image post-processing: Application to instantaneous frequency estimation of M-ary frequency shift keying signals. *Digital Signal Processing*, 127, Article 103535. <https://doi.org/10.1016/j.dsp.2022.103535>
- [32] Lantri, I., Abed, M., & Belouchrani, A. (2025). Hardware implementation of a high-resolution auto-tuned time-frequency signal analyzer over TMS320C6713 DSK using a compact support polynomial kernel. *Microprocessors and Microsystems*, 113, Article 105141. <https://doi.org/10.1016/j.micpro.2025.105141>
- [33] Nahi, A., Abed, M., Larbi, A., & Ouldali, A. (2023). A CNN-BiLSTM mixed model for moving targets' classification from augmented micro-Doppler radar time-frequency distributions' signatures. In *2023 International Symposium on Signals, Circuits and Systems (ISSCS)*. IEEE. <https://doi.org/10.1109/ISSCS58449.2023.10190883>
- [34] Kim, Y., & Ling, H. (2009). Human activity classification based on micro-Doppler signatures using a support vector machine. *IEEE Transactions on Geoscience and Remote Sensing*, 47(5), 1328–1337.
- [35] Flandrin, P. (2018). *Explorations in time-frequency analysis*. Cambridge University Press.
- [36] Burges, C. J. C. (1998). A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2), 121–167.
- [37] Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297.
- [38] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.

- [39] Velog. (n.d.). *CNN Architecture Banner* [Image]. https://velog.velcdn.com/images/dltjrdud37/post/c6c85370-639c-4261-8cef-f418226d66f5/cnn_banner.png
- [40] Neurohive. (2018, novembre). *Architecture du modèle VGG16* [Image]. <https://neurohive.io/wp-content/uploads/2018/11/vgg16.png>
- [41] Wang, X., & Li, H. (2023). *Investigation of Deep Learning Based Semantic Segmentation Models for Autonomous Vehicles* [Figure 3, VGG19 architecture]. ResearchGate. https://www.researchgate.net/figure/GG19-architecture-24_fig3_376180056
- [42] Mahum, R., Munir, H., Mughal, Z.-U.-N., Tlili, I., & Javed, A. (2022). *A novel framework for potato leaf disease detection using an efficient deep learning model* [Figure 3, Detailed architecture of an Efficient DenseNet-201]. ResearchGate. https://www.researchgate.net/figure/Detailed-architecture-of-an-Efficient-DenseNet-201_fig3_36007013.
- [43] Bentoumi, M., Daoud, M., Benaouali, M., & Taleb-Ahmed, A. (2022). *Improvement of emotion recognition from facial images using deep learning and early stopping cross validation* [Figure 10, Architecture of the ResNet50 model and 3-layer bottleneck residual block]. ResearchGate. https://www.researchgate.net/figure/a-Architecture-of-the-ResNet50-model-b-Residual-block-3-layer-bottleneck-block-the_fig10_359733554ResearchGate
- [44] The database of radar echoes from various targets. (2010). [Online]. Retrieved from <https://mega.nz/#!L4Nzxa4K!sSes9SnbRVUUn59Z8bUtg782p685Lv69IVKVx1FzlTw>

