

# Classification SVM d'activités humaines acquises avec radar

Claire BÉRANGER<sup>1</sup> Alexandre BORDAT<sup>1,2</sup> Petr DOBIAS<sup>1</sup> Ngoc-Son VU<sup>1</sup> Julien LE KERNEC<sup>1,3</sup> David GUYARD<sup>2</sup>  
Olivier ROMAIN<sup>1,3</sup>

<sup>1</sup>ETIS Laboratory UMR 8051, CY Cergy Paris Université, ENSEA, CNRS, F-95000 Cergy, France

<sup>2</sup>BlueLinea, 12 Parvis Colonel Arnaud Beltrame, 78000 Versailles, France

<sup>3</sup>James Watt School of Engineering, University of Glasgow, Glasgow, United Kingdom

**Résumé** – Dans un contexte de vieillissement démographique, les études pour la détection de chute chez les personnes âgées s'orientent vers l'utilisation du *radar*, afin d'appuyer les services cliniques et de téléassistance. Après traitements des données radar, il est possible d'obtenir un spectrogramme de l'activité enregistrée. Nous proposons d'extraire des paramètres caractéristiques (tels que l'*Aire*, le *Périmètre* ou encore l'*Orientation*) de la signature d'activité contenue dans le spectrogramme, en utilisant des techniques de traitement d'image. Puis, ces données sont passées en entrée d'une Machine à Vecteurs de Support (SVM) qui est plus légère que d'autres modèles d'apprentissage. Cette méthode atteint une précision de 88,85%, offrant ainsi une solution optimale, peu gourmande en ressources et présentant des performances similaires, voire améliorées vis-à-vis de l'état de l'art.

**Abstract** – In the context of an aging population, fall detection studies are focusing on the use of *radar* to support clinical and teleassistance services. Once the radar data are processed, a spectrogram of the recorded activity can be generated. We propose to extract characteristic parameters (such as *Area*, *Perimeter* or *Orientation*) from the activity signature contained in the spectrogram, using image processing techniques. Then, these data are input into a Support Vector Machine (SVM), which is more lightweight compared to other learning models. This method achieves an accuracy of 88.85%, providing an optimal solution with low resource requirements and similar or even improved performance compared with the state of the art.

## 1 Introduction

De nombreux pays développés sont confrontés au vieillissement de leur population, entraînant un risque de troubles de la motricité et de chutes. Chez les personnes âgées de 65 ans et plus, les chutes ont des conséquences graves, avec en France 20% de la population exposée à ce risque, représentant 10 000 décès et plus de 136 000 hospitalisations par an [6]. À ce jour, les solutions consistent à ce qu'un médecin oriente le patient vers les services appropriés, permettant des tests cliniques pour évaluer la démarche et l'équilibre.

L'utilisation de capteurs intégrés dans des dispositifs tels que les gyroscopes et accéléromètres dans des colliers ou montres permettent de reconnaître des activités comme *Marcher* ou *S'asseoir* [4]. Cependant, cela impose une contrainte pour la personne qui les porte et présente un taux élevé de fausses alertes. Le radar devient une solution prometteuse grâce à son caractère non intrusif et à sa capacité à détecter des micro-mouvements sans capturer d'images visuelles du patient. Les informations recueillies dans l'écho sont représentées en images vitesse-temps (spectrogrammes micro-Doppler) [1].

Des études ont montré qu'il est possible d'identifier les mouvements de chaque membre du corps dans les spectrogrammes [10]. L'allure d'un spectrogramme varie selon l'activité, ce qui permet d'utiliser un modèle de classification sur ces données. Des modèles tels que la Machine à Vecteurs de Support (SVM), les K Plus Proches Voisins (KNN) et GoogLeNet ont obtenu des précisions de reconnaissance allant de 74% à 94%. L'étude [2] a atteint un taux de précision de 87,10% avec un ResNet-18, sans modifier le modèle ni les données.

L'objectif de ce papier est de proposer un modèle de classification léger pour reconnaître les activités humaines à partir de

caractéristiques extraites des spectrogrammes et d'utiliser cette base de connaissances pour classer de nouvelles données. Nous commencerons par expliquer l'obtention des spectrogrammes et de leurs caractéristiques, suivie de la présentation de la méthode de classification basée sur SVM. Une comparaison des résultats avec ceux de l'article [2] sera ensuite effectuée. Enfin, nous proposerons une analyse globale des résultats et des perspectives pour de futurs travaux.


## 2 État de l'art

Cette section présente la méthode suivie pour extraire des données interprétables du radar. Puis, les méthodes de reconnaissance basées sur ces données sont introduites.


### 2.1 Extraction des données radar

Le "Radio Detection And Ranging" (Radar) est une technologie qui utilise des ondes radio pour détecter et suivre des éléments à proximité. Cette technologie est utilisée dans divers domaines tels que la défense, la navigation ou encore la santé. Le principal avantage du radar dans la reconnaissance d'activité est la possibilité d'analyser des signatures Doppler [2]. Le changement de fréquence dû par le mouvement d'un objet est la signature Doppler. Les variations de la signature, lors de mouvements supplémentaires, sont le micro-Doppler.

Pour obtenir ces signatures, le système radar émet une onde radio et mesure les réflexions retournées par les objets alentours. Les données brutes radar sont récupérées pour extraire les informations obtenues. Une Transformation de Fourier Discrète (DFT) y est appliquée pour obtenir les données de



(a) Spectrogramme d'une marche [3]



(b) Extraction de paramètres (*Aire, Périmètre, Orientation, Centroïde*)

FIGURE 1 : Analyse d'un spectrogramme, de l'original à l'extraction de paramètres

distance et de temps. Un filtre est ensuite appliqué pour retirer les éléments non mouvants. Enfin, une Transformation de Fourier à Court Terme (STFT) est réalisée pour obtenir la vitesse par rapport au temps. Cette dernière permet d'extraire les caractéristiques évoluant dans le temps, notamment la signature Doppler. Dans la majorité des études, ce sont des radars à Onde Continue Modulée en Fréquence (FMCW) qui sont utilisés.

Les données en fin de chaîne de pré-traitement sont les spectrogrammes, une représentation visuelle de la vitesse des mouvements en fonction du temps. La Figure 1a montre que le spectrogramme permet de visualiser la distribution de l'énergie du signal. Comme chaque activité comporte sa propre signature, les algorithmes de reconnaissance peuvent différencier les spectrogrammes de deux activités.

Pour les systèmes radar FMCW, la résolution en distance est proportionnelle à la largeur de bande, et la résolution Doppler est liée à la durée de l'onde perçue et au nombre de points FFT utilisés dans la STFT. Dans le cas étudié, la résolution en distance est de 37,5 cm et la résolution Doppler est de 1,25 Hz (ou 0,03 m/s), ce qui permet une analyse exacte de la vitesse et une classification de l'activité.

## 2.2 Reconnaissance d'activités

Des recherches portent sur l'amélioration de modèles de classification appliqués à la reconnaissance d'images, notamment à partir de données radar issues de diverses sources telles que les drones ou les activités humaines [5, 7]. Les modèles les plus étudiés incluent le SVM, KNN, GoogLeNet, AlexNet ou encore ResNet-18 [2, 8, 9]. L'efficacité de ces algorithmes dépend de la quantité minimale de données pour assurer un apprentissage et une validation des résultats fiables.

Des essais ont été réalisés avec le jeu de données *Radar signatures of human activities* [3], montrant la faisabilité d'utiliser des spectrogrammes pour la reconnaissance d'activités humaines. Dans les travaux de [8, 9], AlexNet est utilisé pour l'extraction de caractéristiques, suivi d'un apprentissage par transfert (Transfer Learning) vers des modèles SVM et KNN, atteignant respectivement 78,25% et 77,15% de précision. Le Transfer Learning consiste à utiliser les connaissances acquises par un modèle de classification au préalable, puis à les réutiliser pour résoudre un problème différent, mais similaire [8, 9].

ResNet-18 est un modèle simple qui comporte 18 couches, ce qui est peu, il offre des précisions de 70% à 90% sans optimisation particulière. Dans les travaux de [2], il a été retenu pour sa simplicité et son nombre réduit de paramètres, idéal pour des solutions embarquées à faible empreinte. Une précision de 87,10% a été obtenue sans modification du modèle ni des données.

Bien que ResNet-18 soit performant, son architecture reste plus lourde et coûteuse en calcul que d'autres approches. Le SVM est une alternative intéressante pour des solutions embarquées, puisqu'il est léger, rapide à entraîner et peu gourmand en ressources, permettant une classification efficace à partir de caractéristiques extraites.


## 3 Méthodologie appliquée

Les méthodes d'obtention des données d'entrée et le modèle de classification choisi sont exposées dans cette section.


### 3.1 Génération des spectrogrammes

L'ensemble de données *Radar signatures of human activities* [3] est utilisé pour toutes les expérimentations, étant le plus complet et adapté à nos travaux. Nous utilisons la chaîne de pré-traitement proposée par les auteurs afin d'obtenir les spectrogrammes correspondants. Le jeu de données comporte 1 753 images réparties non équitablement entre 6 activités humaines, avec environ 310 images pour chaque activité, sauf pour la *Chute* qui en comporte seulement 198.

Les spectrogrammes obtenus, nous faisons le choix d'en extraire uniquement les informations de la signature de l'activité à l'aide d'une binarisation de l'image. Dans les travaux de [2], les spectrogrammes sont inchangés. Nous souhaitons ici utiliser un modèle léger de type SVM. L'usage de caractéristiques de forme semble approprié pour optimiser le taux de stockage d'informations. L'*Aire*, le *Périmètre*, l'*Orientation*, le *Majeur*, le *Mineur*, les *Centroïdes X et Y* ainsi que l'*Excentricité* de la forme de la signature sont extraits à l'aide de méthodes mathématiques et de traitements de la librairie python *skimage*. Toutes ces informations illustrées sur la Figure 1b, obtenues à partir de la Figure 1a, sont stockées dans un fichier textuel.



(a) Modèle utilisant le noyau RBF



(b) Modèle utilisant le noyau Polynomial avec ACP

FIGURE 2 : Matrices de confusion normalisées

### 3.2 Choix des paramètres

Le jeu de données *Radar signatures of human activities* [3] contient deux activités similaires, *Ramasser* et *Boire*. Le papier [2] a montré cette confusion, que nous proposons de limiter en combinant ces activités sous l'étiquette *Autre*. Nous travaillons avec 5 activités : *Marcher*, *S'asseoir*, *Se lever*, *Autre*, *Chuter*.

Le noyau du modèle SVM est choisi en fonction des 5 meilleures précisions obtenues après avoir exploré différents paramètres extraits des signatures contenues dans les spectrogrammes. Nous comparons les noyaux gaussien (RBF) et Polynomial, plus adaptés à nos données, pour déterminer le noyau et les paramètres les plus pertinents à utiliser.

Enfin, nous proposons également d'appliquer une Analyse en Composantes Principales (ACP) centrée pour réduire la dimensionnalité des données, synthétiser leur variation et comparer les résultats avec ou sans cette technique. L'objectif est d'optimiser les paramètres et hyper-paramètres du modèle.

### 3.3 Méthode de classification

Les études [2] ont mis en avant la possibilité de reconnaître des activités avec une méthode de reconnaissance simple à mettre en œuvre. Le ResNet-18 a permis de réaliser de premiers apprentissages basés directement sur les spectrogrammes obtenus à la sortie d'une acquisition radar. Cependant, nous nous interrogeons sur l'usage d'un autre moyen d'interprétation des signatures tout en préservant une solution simple et légère.

Un SVM *One-vs-Rest* est proposé pour apprendre sur des spectrogrammes dont on aura extrait des caractéristiques. Le SVM est une solution légère, rapide et très efficace sur des ensembles de données peu fournis. De plus, cela permet de stocker de moins grandes quantités d'information. Le SVM *model* de la librairie python *sklearn* est utilisé. Le type de noyau est déterminé à partir des résultats obtenus avec les données extraites.

Une analyse de maximisation des hyper-paramètres et des paramètres a été réalisée afin de les déterminer. Les méthodes python *GridSearchCV* et *RandomizedSearchCV* ont

été utilisées avec cross-validation pour déterminer les hyper-paramètres du modèle SVM. Les paramètres en entrée du SVM sont déterminés par tests successifs de toutes les combinaisons possibles. Par comparaison avec l'étude [2], nous avons scindé nos données selon la même méthodologie. Nous obtenons 85% des données de chaque classe pour l'entraînement et 15% pour le test.

## 4 Résultats et discussion

Cette section détaille les résultats obtenus, de l'extraction des paramètres à l'apprentissage réalisé sur ces données.

### 4.1 Extraction et sélection des paramètres

Pour pouvoir extraire convenablement les données caractéristiques du spectrogramme, l'image est binarisée comme montré en Figure 1b. Après binarisation, la signature de l'activité contenue dans le spectrogramme est récupérée par extraction de contour. Les 8 paramètres que nous avons cité précédemment dont l'*Aire*, le *Périmètre* et l'*Orientation* peuvent être récupérés. Sur la Figure 1b, on peut identifier l'*Aire* (forme contenue dans le contour rouge), l'*Orientation* (trait orange) et les coordonnées du *Centroïde* (point vert).

Les paramètres extraits peuvent être utilisés comme entrées pour le SVM mais leur pertinence individuelle doit être évaluée afin d'optimiser la reconnaissance. L'objectif est de déterminer s'il est nécessaire de conserver l'ensemble des paramètres ou si une sélection réduite permettrait d'alléger davantage la solution. En testant toutes combinaisons possibles, de 2 paramètres jusqu'à la totalité, il apparaît qu'un sous-ensemble de 5 à 6 paramètres suffit à obtenir une précision de reconnaissance suffisante, avoisinant les 80%.

### 4.2 Application d'un SVM

Un SVM est mis en place pour apprendre sur les paramètres extraits des signatures de spectrogrammes. L'*Aire*, le *Périmètre*, l'*Orientation*, le *Majeur*, le *Mineur*, le *Centroïde X*,

le *Centroïde Y* et l'*Excentricité* peuvent ainsi être utilisés en entrée du modèle.

Le SVM est évalué en testant l'ensemble des combinaisons possibles parmi les paramètres extraits, en utilisant deux types de noyaux (RBF et Polynomial) ainsi que deux approches : SVM classique et SVM avec réduction de dimension par ACP. Avec le SVM classique, le meilleur résultat obtenu est une précision de 88,50% avec le noyau RBF en utilisant les paramètres suivants : *Aire*, *Périmètre*, *Orientation*, *Majeur*, *Mineur*, *Centroïde X*, *Centroïde Y*. La Figure 2a illustre la matrice de confusion correspondante, où l'on observe un faible taux de confusion entre les classes.

Tandis que le SVM avec réduction de dimension par ACP en utilisant un noyau Polynomial permet d'obtenir une précision de 88,85%. Cette configuration repose sur les paramètres suivants : *Orientation*, *Majeur*, *Mineur*, *Centroïde X*, *Centroïde Y*, *Excentricité*. La matrice de confusion associée est présentée en Figure 2b. Dans les deux cas, les matrices montrent des résultats prometteurs, avec des diagonales bien marquées et très peu de confusion entre les classes. Néanmoins, la méthode intégrant l'ACP atteint une précision légèrement supérieure.

### 4.3 Avantage du SVM face au ResNet-18

Avec l'usage de SVM on constate une légère amélioration dans la reconnaissance d'activité vis-à-vis de ResNet-18. La combinaison d'activités a déjà permis de retirer une part de la confusion. Puis, la méthode d'apprentissage basée sur les paramètres extraits grâce à des méthodes de traitement d'image a permis d'affiner également ces résultats de l'ordre de plus de 1%.

Ces résultats nous permettent de confirmer l'importance de la définition de la signature contenue dans les spectrogrammes. Plus les données sont caractéristiques d'une activité plus il est possible de reconnaître des activités basées sur ce type de données. La signature contient l'essentiel de l'information qui permet de discriminer une activité d'une autre.

Les travaux de [2] basés sur le dataset [3] avaient permis d'obtenir une précision de 87,10%. Les résultats obtenus ici démontre qu'il est tout à fait envisageable d'opter pour une solution légère, rapide d'exécution et qui consomme peu en ressources. Notre méthodologie propose de ne conserver que les données réellement utile et donc d'optimiser la chaîne de traitement pour la reconnaissance tout en assurant les performances.

## 5 Conclusion

Ce papier présente une méthode de reconnaissance d'activités humaines basée sur des données radar. L'étude s'appuie sur le jeu de données [3] pour obtenir des spectrogrammes, à partir des données brutes radar. Des paramètres caractéristiques de l'activité en sont extraits pour les utiliser comme entrées d'un SVM. Une précision de 88,85% a ainsi pu être obtenue. Cette méthode, tout en restant légère et peu coûteuse en ressources, est compétitive avec les approches de l'état de l'art.

Ces résultats montrent qu'on peut traiter des données radar complexes en extrayant des caractéristiques simples et exploitables. Nos travaux futurs visent à trouver et améliorer des méthodes de reconnaissance d'activité légères et à développer un système embarqué temps-réel.

## Références

- [1] Alexandre BORDAT, Petr DOBIAS, Julien LE KERNEC, David GUYARD et Olivier ROMAIN : Towards Real-Time Implementation for the Pre-Processing of Radar-Based Human Activity Recognition. In *2022 IEEE 31st International Symposium on Industrial Electronics (ISIE)*, pages 635–638, Anchorage, AK, USA, juin 2022. IEEE.
- [2] Claire BÉRANGER, Alexandre BORDAT, Mohamed Amine KHELIF, Petr DOBIAS, Ngoc-Son VU, Julien LE KERNEC, David GUYARD et Olivier ROMAIN : Radar-based human activity acquisition, classification and recognition towards elderly fall prediction. In *2023 26th Euromicro Conference on Digital System Design (DSD)*, pages 95–102, Golem, Albania, septembre 2023. IEEE.
- [3] Dr Francesco FIORANELLI, Dr Syed Aziz SHAH, Haobo LI1, Aman SHRESTHA, Dr Shufan YANG et Dr Julien LE KERNEC : Radar sensing for healthcare : Associate Editor Francesco Fioranelli on the applications of radar in monitoring vital signs and recognising human activity patterns. *Electronics Letters*, 55(19):1022–1024, septembre 2019.
- [4] Sylvain ILOGA, Alexandre BORDAT, Julien LE KERNEC et Olivier ROMAIN : Human Activity Recognition Based on Acceleration Data From Smartphones Using HMMs. *IEEE Access*, 9:139336–139351, 2021.
- [5] Zhenghui LI : *Radar sensing for Ambient Assisted Living application with Artificial Intelligence*. Thèse de doctorat, James Watt School of Engineering, University of Glasgow, Glasgow, United Kingdom, 2024.
- [6] Torres MARION, Pédrone GAËLLE, Lasbeur LINDA, Carcaillon-Bentata LAURE, Rigou ANNABEL et Beltzer NATHALIE : *Chutes des personnes âgées à domicile. Caractéristiques des chuteurs et des circonstances de la chute. Volet « Hospitalisation » de l'enquête ChuPADom, 2018. Études et enquêtes, 2020.*
- [7] Dongsuk PARK, Seungeui LEE, SeongUk PARK et Nojun KWAK : Radar-Spectrogram-Based UAV Classification Using Convolutional Neural Networks. *Sensors*, 21(1): 210, décembre 2020.
- [8] Syed Aziz SHAH et Francesco FIORANELLI : Human Activity Recognition : Preliminary Results for Dataset Portability using FMCW Radar. In *2019 International Radar Conference (RADAR)*, pages 1–4, TOULON, France, septembre 2019. IEEE.
- [9] William TAYLOR, Kia DASHTIPOUR, Syed Aziz SHAH, Amir HUSSAIN, Qammer H. ABBASI et Muhammad A. IMRAN : Radar Sensing for Activity Classification in Elderly People Exploiting Micro-Doppler Signatures Using Machine Learning. *Sensors*, 21(11):3881, juin 2021.
- [10] Shelly VISHWAKARMA : *Learning Algorithms For Micro-Doppler Radar Based Detection, Classification and Imaging of Humans in Indoor Environments*. Thèse de doctorat, Indraprastha Institute of Information Technology, Delhi, 2020.