

Utilisation des Random Forests pour la reconnaissance d'activité humaine: une étude complète avec le jeu de données d'Opportunity

Luis Giovanni, Christel Dartigues-Pallez, Stéphane Lavirotte, Jean-Yves Tigli
Université Côte d'Azur, CNRS, I3S (UMR 7271)
930, Route des Colles 06903 Sophia Antipolis, France
Prenom.Nom@unice.fr

RÉSUMÉ

Un grand nombre de recherches existent pour la reconnaissance d'activité humaine. Cependant, la plupart d'entre elles utilisent un ensemble statique et immuable de capteurs connus par avance. Cette approche ne fonctionne pas lorsqu'elle est appliquée à un système ubiquitaire, car nous ne connaissons alors pas par avance quels capteurs seront disponibles dans l'environnement de l'utilisateur. C'est pourquoi nous considérons ici une approche opportuniste où chaque capteur est entraîné individuellement et capable d'apporter sa propre connaissance. Nous considérons toutes les étapes de la chaîne de reconnaissance d'activité et nous montrons comment ce processus peut être amélioré à chacune de ces étapes. Plus précisément, nous prenons en compte les étapes telles que le prétraitement, la segmentation, l'extraction de caractéristiques et l'apprentissage. Nous proposons également d'évaluer à la fois l'efficacité des Random Forests (RF) pour entraîner des capteurs et la robustesse de la fusion des résultats basée sur le vote à la majorité en comparant les résultats obtenus à ceux du projet Opportunity. Nous montrons ainsi que les RF donnent de meilleurs résultats plus robustes que les algorithmes d'apprentissage testés par Opportunity.

Mots clés

Reconnaissance d'activité, multi-capteurs; capteurs portés; informatique vestimentaire ; reconnaissance opportuniste.

1. INTRODUCTION

Les progrès de ces dernières années dans l'intégration des différents types de capteurs dans les objets du quotidien, tels que des bracelets, des ceintures et des téléphones ont conduit à l'émergence de nouveaux champs de recherche dans la reconnaissance de l'activité humaine. Les approches guidées par les données se basent sur des techniques d'apprentissage qui reposent sur la mise en correspondance entre les signaux des capteurs et les classes représentant les activités. La reconnaissance d'activité peut être ramenée à un problème de classification, avec les caractéristiques extraites des données des capteurs comme données d'entrée, et les activités comme sortie de l'algorithme d'apprentissage. Tout le processus partant de l'extraction des données à partir des capteurs et allant jusqu'à l'entraînement du modèle de reconnaissance d'activité est appelé la Chaîne de Reconnaissance d'Activité.

Le principal problème de ces approches est que les entrées et sorties sont prédéfinies au moment de l'étape de conception du système, avec un ensemble de capteurs (portés ou déployés dans l'environnement) spécifique, précis et fixe qui est couplé avec les méthodes utilisées pour reconnaître une activité.

Cependant, la disponibilité des différents capteurs portés dans la vie quotidienne (accéléromètres, magnétomètres inclus dans les objets portables) ainsi que l'augmentation de l'ajout des capteurs embarqués dans l'environnement (capteurs ambiants) nécessite de définir et concevoir une nouvelle approche pour reconnaître les activités. Cette approche doit exploiter tous les capteurs disponibles, qui peuvent être hétérogènes et peuvent apparaître (ou disparaître) spontanément dans l'environnement ou sur l'utilisateur. Cette émergence de nouvelles ressources participant au processus de reconnaissance d'activité va à l'encontre de l'approche traditionnelle et statique où toutes les informations disponibles sont connues lors de l'étape de conception du système.

Le besoin de développer une adaptation dynamique des configurations de capteurs qui apparaissent/disparaissent de manière opportuniste a été étudiée dans le projet Européen Opportunity [1]. Dans ce projet, ils définissent un cadre global pour rendre possible l'utilisation opportuniste de capteurs pour la reconnaissance d'activités humaines.

Dans ce papier nous avons concentré notre travail sur deux parties importantes du processus de Reconnaissance d'Activité Humaine : un apprentissage spécifique pour chaque capteur pour permettre la reconnaissance d'activité et un processus de fusion des décisions individuelles. Nous proposons d'améliorer les résultats obtenus par le projet Opportunity en introduisant l'utilisation des Random Forests (RF) qui n'avaient pas été considérées. Nous proposons également une stratégie efficace de fusion des décisions. Ces deux propositions ont été évaluées sur le jeu de données d'Opportunity. Nous montrerons dans ce papier leurs avantages ainsi que les meilleurs résultats que nous avons obtenus grâce à leur utilisation.

2. APPROCHE OPPORTUNISTE

La reconnaissance d'activité humaine est un champ de recherche qui a pris de l'ampleur au cours des dernières années. Il existe deux approches distinctes pour permettre la reconnaissance d'activité : les approches guidées par la connaissance et les approches guidées par les données. Les approches guidées par la connaissance utilisent soit le raisonnement logique soit le raisonnement ontologique. Cependant, ces approches impliquent de gérer un modèle de représentation des connaissances très précis des activités qui doivent être reconnues. De plus, il manque des processus d'apprentissage pour faire face aux incertitudes du modèle. Ces inconvénients font que ce type d'approche n'est pas adapté à notre problème qui doit tirer avantage de l'information recueillie lors de l'exécution à partir de capteurs hétérogènes et non connus à la conception du système.

2.1 Processus de Reconnaissance d'Activité

Les approches guidées par les données peuvent être divisées en deux catégories : les approches non supervisées et les approches supervisées. Les approches non supervisées telles que les méthodes d'extraction de motifs fréquents ou périodiques nécessitent une longue phase de collecte des données et ont un temps d'exécution long qui les rendent difficilement utilisables dans la pratique. Les approches supervisées sont basées sur des techniques d'apprentissage utilisant les données des capteurs comme entrée. Le problème de reconnaissance d'activité peut être ainsi réduit à un problème de classification, avec des caractéristiques extraites à partir des données de capteurs comme données d'entrée, et les activités déduites comme données de sortie de l'algorithme d'apprentissage. Le processus partant de l'extraction des données à partir des capteurs et allant jusqu'à l'entraînement d'un modèle pour reconnaître des activités est appelé la Chaîne de Reconnaissance d'Activité. Ce processus est classiquement divisé en différentes étapes qui sont toute d'une importance cruciale: acquisition des données, prétraitement, segmentation, extraction de caractéristiques et classification.

Une fois que les données d'entrées sont recueillies à partir de tous les capteurs (acquisition de données), le processus de reconnaissance commence par nettoyer les données brutes (prétraitement). Le sous-ensemble de données sur lequel le processus de reconnaissance est appliqué est alors extrait (segmentation). Cela peut être réalisé à l'aide de deux techniques : la technique de fenêtre glissante ou l'analyse de changement d'activité. La technique de la fenêtre glissante est la plus utilisée à cause de sa simplicité (aucun prétraitement n'est nécessaire) et des bons résultats qu'elle permet d'obtenir. Chaque fenêtre glissante se chevauche avec la précédente pour garantir une consistance temporelle. Les données contenues dans chaque fenêtre sont transformées en un vecteur de caractéristiques (extraction de caractéristiques). Des caractéristiques communes (représentant la moyenne, la variance, l'entropie, etc.) sont alors utilisées comme données d'entrée pour un classifieur. Il existe de nombreux classifieurs supervisés : Support Vector Machines (SVM), k plus proches voisins (k-NN), classifieur basé sur le plus proche cluster (NCC), arbres de décision, réseaux de neurones, etc. Chaque classifieur supervisé doit être entraîné avec des données spécifiques (appelées données d'entraînement) pour pouvoir reconnaître des classes (les activités de l'utilisateur dans notre cas).

Parmi toutes les approches possibles dans le contexte de la reconnaissance d'activité humaine, les approches basées sur les multi-classifieurs semblent être les plus prometteuses. Les Random Forests (RF) sont un bon exemple de telles méthodes. Les RF ont été utilisées pour reconnaître des postures humaines à partir d'images de profondeur fournies par une Kinect (Shotton et al. [2]). De manière similaire, les RF ont été utilisées avec d'autres types de données de capteurs avec des résultats très prometteurs [3]. Les RF font partie des méthodes d'apprentissage supervisé.

Cette technique nécessite un jeu de données labélisées coupé en deux sous-ensembles : un ensemble d'apprentissage utilisé pour construire la forêt et un ensemble de test pour tester la précision de la forêt. Une forêt est composée d'un ensemble d'arbres de décision. Ce classifieur se base sur deux notions importantes : le Bagging (chaque arbre de la forêt est construit à partir d'un sous-ensemble de l'ensemble d'apprentissage, sous-ensemble qui est choisi au hasard) et la Random Feature Selection (chaque nœud de chaque arbre est sélectionné en choisissant la meilleure caractéristique parmi un sous-ensemble des caractéristiques représentant les données, sous ensemble qui est choisi au hasard).

La Figure 1 illustre le processus de création d'une forêt. Chaque donnée de l'ensemble d'apprentissage est représentée par un vecteur de caractéristiques (dans notre cas les données émises par les capteurs). Un sous-ensemble de l'ensemble d'apprentissage est sélectionné aléatoirement pour construire chaque arbre (Bagging). Dans ce sous-ensemble, chaque donnée est représentée par un vecteur de caractéristiques. Un sous-ensemble des caractéristiques composant ce vecteur est sélectionné à chaque fois qu'un nœud de l'arbre doit être construit (Random Feature Selection) et la meilleure caractéristique sera choisie pour construire le nouveau nœud de l'arbre.

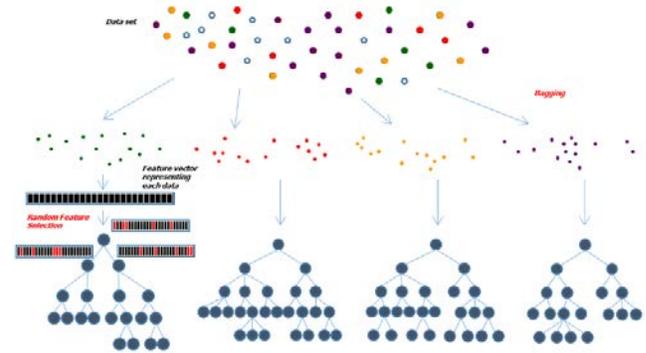


Figure 1. Processus de création des Random Forest (RF)

Le processus de reconnaissance est constitué de différentes étapes qui sont toutes sujettes à des personnalisations et améliorations pour obtenir de meilleurs résultats de reconnaissance.

2.2 Fusion de signal et de décision

La reconnaissance d'activité humaine est un champ de recherche qui s'est montré très actif ces toutes dernières années. Cependant, dans les études sur ce domaine le nombre de capteurs considéré est souvent fixé dès le début de l'expérimentation et ne sont pas supposés changer par la suite. L'ensemble de capteurs est donc statique et immuable. Dans ce contexte, le processus de reconnaissance d'activité est basé sur l'ensemble des caractéristiques fourni par tous les capteurs. Ces caractéristiques sont données à un seul classifieur qui est entraîné pour la reconnaissance d'activité (les classes) en fonction des signaux fournis par les capteurs (Figure 2).

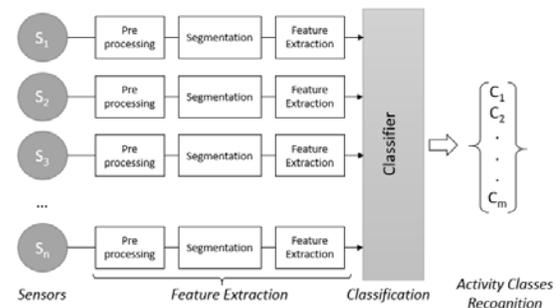


Figure 2: Classification basée sur la fusion de signal

Cependant, cette approche a un inconvénient majeur : si des capteurs manquent, les résultats vont en souffrir et si on souhaite ajouter un nouveau capteur le processus d'entraînement doit alors être entièrement refait avant que ce nouveau capteur puisse être pris en considération. Pour toutes ces raisons, cette approche n'est pas adaptée à un système ubiquitaire car nous ne pouvons pas savoir par avance quels capteurs vont être disponibles. C'est la raison pour

laquelle nous considérons dans cette étude une approche opportuniste dans laquelle un classifieur est entraîné pour chaque capteur et apporte ainsi sa propre connaissance à un processus global de décision.

Une fois que chaque capteur a appris individuellement à partir des données qu'il émet, nous pouvons considérer une approche opportuniste qui considère des combinaisons de capteurs spécifiques à un moment donné. Pour reconnaître les activités résultant de la combinaison de capteurs, nous avons besoin de combiner les décisions données par chacun des classifieurs des capteurs (Figure 3).

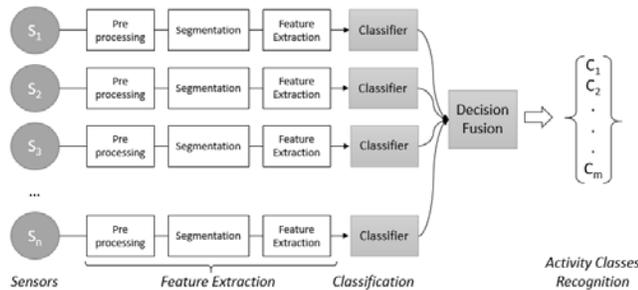


Figure 3: Classification basée sur la fusion de décisions de capteurs

Comme nous simulons une approche opportuniste, nous ne pouvons pas utiliser des techniques de fusion qui nécessitent une phase d'entraînement. Cela est dû au fait que, dans un système ubiquitaire, les combinaisons ne sont pas statiques et peuvent (et vont très certainement) changer lors de l'exécution. Nous devons ainsi considérer la possibilité d'ajouter de nouveaux capteurs encore inconnus de notre système à n'importe quel moment.

Par conséquent, nous avons opté pour une méthode qui combine les résultats de chaque capteur mais qui ne repose pas sur un processus d'apprentissage : un vote à la majorité. Nous avons testé quatre façons différentes de réaliser ce vote à la majorité avec les informations provenant des processus individuels d'apprentissage.

3. Expérimentations

Les jeux de données produits pour la reconnaissance d'activités humaine à partir de données issues de capteurs [4] sont nombreux, mais celui produit par le projet Opportunity se démarque. Il propose un jeu de données collectant des informations sur les activités de la vie quotidiennes à partir d'un environnement très riche en capteurs : « 72 capteurs de 10 modalités inclus dans 15 systèmes de capteurs connectés ou sans fil répartis dans l'environnement, dans les objets et sur l'utilisateur » [4].

Les Figures 4 et 5 (issues du projet Opportunity) montrent la répartition et la position de ces capteurs sur le corps humain. Ce jeu de données, collectant les informations de 12 sujets effectuant des activités matinales, peut être utilisé pour reconnaître des types de déplacement et de gestes.

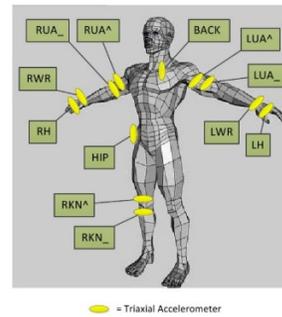


Figure 4. Positionnement des capteurs IMU sur le corps

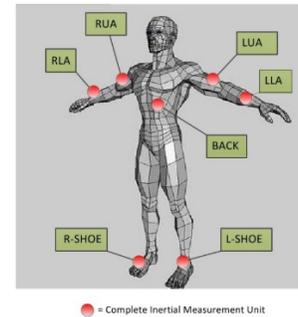


Figure 5. Positionnement des accéléromètres

Parmi tous ces capteurs, l'équipe d'Opportunity a utilisé 7 méta-capteurs, chacun d'eux intégrant des capteurs physiques réels sur les différentes parties du corps. Ces capteurs sont : RKN (« Right Knee », genou droit), SHOE (chaussure), LUA (« Left Upper Arm », haut du bras gauche), LLA (« Left Lower Arm », bas du bras gauche), RUA (« Right Upper Arm », haut du bras droit), RLA (« Right Lower Arm », bas du bras droit) et BACK (dos).

Parmi les activités à reconnaître, nous avons extrait du jeu de données les activités portant sur les modes de locomotion : se tenir debout, marcher, se tenir assis, être couché et une classe null représentant les états de transition qui ne peuvent être catégorisés dans une des quatre classes mentionnées. Avec ce jeu de données, le projet Opportunity a aussi fourni un test de référence. Ce test a été le point de départ pour un défi sur le jeu de données d'Opportunity.

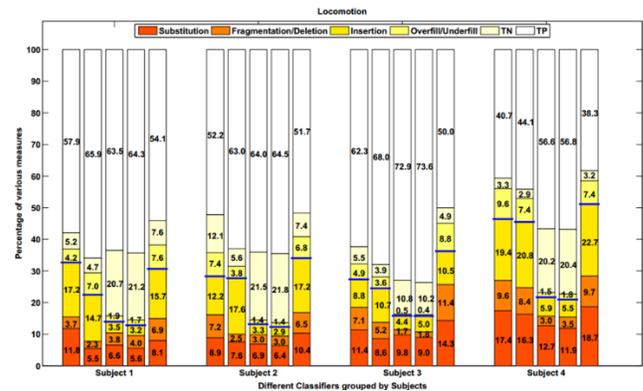


Figure 6: Evaluation des performances sur le jeu de données du concours Opportunity pour les modes de locomotions (utilisation des mesures proposées par Ward et al.)

Chavarriga et al. [10] présentent les résultats obtenus au défi (Figure 6) et mettent en évidence que les résultats obtenus avec les méthodes de classification 1-NN et 3-NN (colonnes 3 et 4 pour chacun des sujets Figure 6) sont meilleures si on les compare aux méthodes de classification Linear Discriminant Analysis (LDA), Quadratic Discriminant Analysis (QDA) (colonnes 1 et 2 Figure 6) et le classifieur NCC (colonne 5).

3.1 Evaluation de la méthode d'apprentissage Random Forest avec l'ensemble des capteurs

Nous avons testé plusieurs autres méthodes de classification à l'aide de ce jeu de données. Les résultats obtenus avec le classifieur Random Forest sont meilleurs que les résultats originaux obtenus lors du défi proposé par le projet Opportunity. La Figure 7 ajoute

les résultats obtenus avec le classifieur Random Forest (la dernière colonne pour chacun des sujets) aux résultats obtenus précédemment par le projet Opportunity (Figures 4).

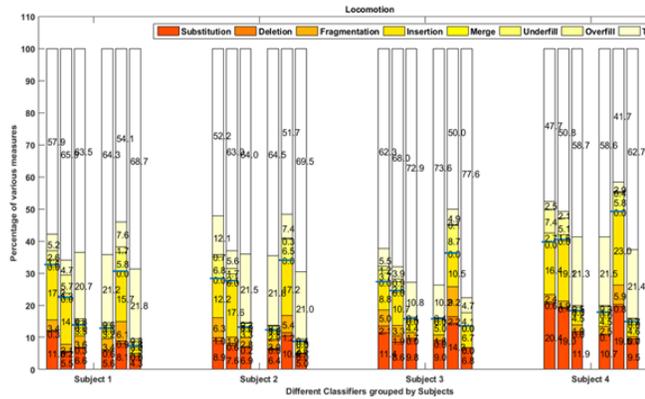


Figure 7: Ajout des résultats pour la méthode Random Forest

Cependant, dans cette approche, il n'y a qu'un seul classifieur entraîné avec les données de l'ensemble des capteurs à chaque instant. Ce n'est donc pas une approche opportuniste puisque les capteurs n'ont pas appris individuellement pour ensuite combiner les résultats afin d'obtenir une décision globale.

3.2 Apprentissage individuel des capteurs

Pour adopter la reconnaissance d'activité opportuniste proposé dans le projet Opportunity, nous avons entraîné les mêmes sept groupes de capteurs séparément. Un apprentissage classique a été appliqué en suivant différentes étapes distinctes : traitement du signal, extractions des caractéristiques et apprentissage. Nous avons utilisé les données des sujets 1, 2 et 3 en utilisant les fichiers ADL1, 2, 3 et Drill pour l'apprentissage et les sujets 4 et 5 (ADL 4 et 5) pour les tests.

3.2.1 Étape de prétraitement

La première optimisation étudiée est l'étape de traitement du signal pour examiner les données manquantes dues aux incohérences lors des communications sans fil. Il y a environ 4,10% de données manquantes dans l'ensemble d'apprentissage et 2,10% dans l'ensemble de test. Ce problème a dû être pris en compte afin de ne pas introduire un biais dans le processus d'apprentissage. Nous avons testé plusieurs techniques d'interpolation pour traiter ces données manquantes : ignorer les données manquantes, remplacer celles-ci par la moyenne des valeurs ou bien d'effectuer une interpolation de type linéaire ou spline. Nous avons pu obtenir de meilleurs résultats pour gérer ces valeurs manquantes en les estimant à l'aide d'une interpolation à base de splines.

Jeu de données	Nb Valeurs	Valeurs manquantes	Pourcentage
Apprentissage	65.164.354	2.673.553	4,10%
Test	13.769.209	289.178	2,10%

Table 1. Données manquantes dans le jeu de données

3.2.2 Segmentation

Les valeurs issues des capteurs étant récupérées de manière continue, il est nécessaire de mettre en œuvre une technique de segmentation dans ce flux de données. La technique utilisée par le projet Opportunity est basée sur une méthode de fenêtre glissante pour évaluer les caractéristiques (moyenne et variance) des données reçues durant une tranche de temps correspondant à 15 instants et un pas de décalage de la tranche de temps de 8 instants (donc avec 7 instants de recouvrement).

Nous avons testé de nombreuses configurations pour la taille de la fenêtre de temps et l'incrément de décalage de cette fenêtre. Les différentes tailles et décalages utilisés sont : 15/8, 30/15, 45/23, 45/15, 60/15, 60/30, 75/38 and 90/45 (Table 2 et Figure 8).

	W:15 S:8	W:30 S:15	W:45 S:23	W:45 S:15	W:60 S:15	W:60 S:30	W:75 S:38	W:90 S:45
1NN	0.854	0.857	0.857	0.866	0.859	0.860	0.857	0.852
3NN	0.861	0.863	0.872	0.873	0.866	0.870	0.868	0.872
RF	0.870	0.874	0.876	0.879	0.881	0.876	0.875	0.873

Table 2. Effet de la taille/décalage des fenêtres glissantes sur les résultats de reconnaissance

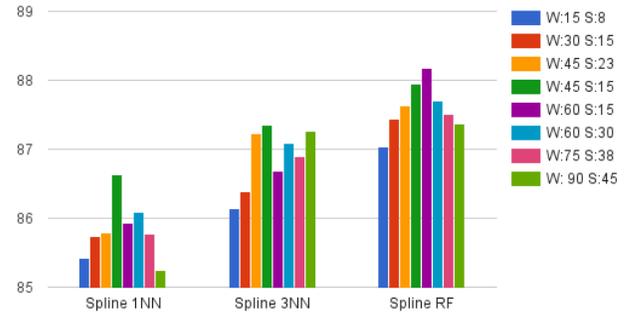


Figure 8. Impacte des paramètres de taille/décalage de la fenêtre glissante sur les résultats (avec les caractéristiques: moyenne, variance, min, max, entropie)

3.2.3 Extraction des caractéristiques

Nous avons extrait les caractéristiques à partir de la méthode de fenêtre glissante. Le projet Opportunity avait utilisé uniquement les données de moyenne et de variance des valeurs pour une fenêtre. Nous avons évalué d'autres caractéristiques qui pouvaient être pertinentes pour ce jeu de données : minimum, maximum, entropie et Kurtosis. Nous avons pris une fenêtre glissante de 40 ou 60 instants et un décalage de cette fenêtre de 15 instants, fenêtres pour laquelle nous avons obtenu les meilleurs résultats lors de l'étape de segmentation. Étant donnée la fréquence d'échantillonnage, cela correspond à une fenêtre de 1,5 à 2 secondes avec un décalage de la fenêtre de 0,5 seconde. Ceci confirme les résultats obtenus avec d'autres jeux de données [15] pour ces types de capteurs.

	MeanVar	+MinMax	+Entropy	+Skewness	+Kurtosis
1NN	0.749	0.853	0.854	0.602	0.599
3NN	0.760	0.861	0.861	0.611	0.611
RF	0.842	0.869	0.870	0.868	0.864

Table 3. Performances fonction des caractéristiques

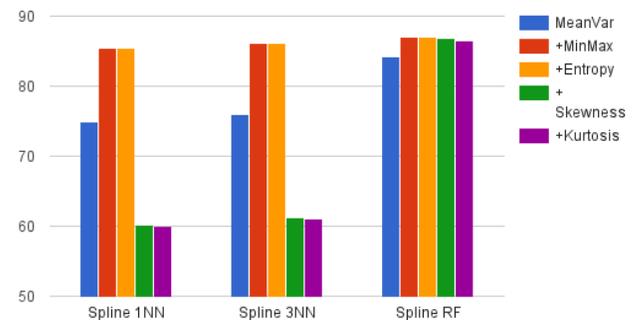


Figure 9. Impact des caractéristiques sur les méthodes de classification

Toutes les expérimentations effectuées avec les différentes combinaisons de caractéristiques (Figure 9) font apparaître que le

nombre et le type des caractéristiques retenues ont un faible impact sur les résultats obtenus avec la méthode Random Forest, mais ont un impact plus significatif sur les méthodes 1-NN et 3-NN. Ceci peut être expliqué par le processus de création de la forêt aléatoire : la sélection aléatoire de valeurs discriminantes. Ainsi, Random Forest donne une meilleure stabilité des résultats obtenus ainsi qu'une meilleure précision comparée aux méthodes 1-NN et 3-NN.

3.2.4 Classification

Enfin, nous avons entraîné chaque groupe de capteurs avec les caractéristiques extraites. Nous avons choisi de comparer trois classifieurs: 1-NN et 3-NN (car ce sont ceux qui ont obtenu les meilleurs résultats lors du défi Opportunity) et un classifieur Random Forest.

Notre approche est basée sur l'utilisation de Random Forest, comme dans [3]. Mais contrairement aux autres études, nous n'avons pas considéré toutes les données fournies par tous les capteurs lors de la phase d'apprentissage. Nous nous plaçons dans un processus totalement ubiquitaire : les capteurs ne sont pas connus à l'avance, ils peuvent apparaître et disparaître, conduisant à des configurations dynamiques non anticipables à la conception du système. En entraînant indépendamment chaque capteur à reconnaître une activité à l'aide de Random Forest, il devient nécessaire de combiner les décisions fournies par chacun des capteurs d'une manière adaptée.

	RKN	SHOE	LUA	LLA	RUE	RLA	BACK
Opportunity	0.604	0.698	0.858	0.719	0.769	0.709	0.761
1NN	0.694	0.708	0.834	0.792	0.811	0.785	0.811
3NN	0.709	0.719	0.835	0.795	0.814	0.798	0.813
RF	0.742	0.774	0.835	0.896	0.820	0.797	0.855

Table 4. Résultat d'apprentissage pour chaque capteur individuellement

Comme montré dans la Table 4, la méthode Random Forest surclasse les méthodes k-NN pour 5 des 7 groupes de capteurs. Et quand les méthodes k-NN sont meilleures, la différence de précision est très faible. De plus, à l'exception du capteur LUA, les résultats sont meilleurs que ceux obtenus par le projet Opportunity.

3.3 Fusion de décisions

Comme nous l'avons vu précédemment, les résultats références sur le jeu de données du projet Opportunity ont été obtenus avec un processus d'apprentissage utilisant les données de tous les capteurs connus. Ainsi, ces résultats de référence [10] ne sont pas obtenus dans l'optique d'une approche opportuniste, mais en entraînant un seul classifieur de manière classique. Comme décrit dans la Figure 2, les données extraites des différents signaux issus des capteurs sont combinées et fournies comme l'entrée d'un seul classifieur.

Quand chaque capteur a été entraîné individuellement à reconnaître les activités, il est alors nécessaire de fusionner les résultats fournis par chacun des capteurs proposant une décision. Il est possible de simuler une approche opportuniste en entraînant et en considérant les résultats fournis par différentes combinaisons de capteurs. Pour tester cette fusion de décisions de chacun des capteurs, nous avons tout d'abord utilisé les 13 combinaisons différentes testées par le projet Opportunity dans les tests qu'ils ont effectué dans [3] afin de comparer les résultats obtenus.

Puisque nous simulons une approche opportuniste, il n'est pas possible d'utiliser une technique de fusion nécessitant un apprentissage. En effet, dans un système ubiquitaire, les combinaisons de capteurs ne sont pas statiques et peuvent (et vont certainement) évoluer lors de l'exécution. De plus, nous devons pouvoir prendre en compte les résultats de nouveaux capteurs

introduit dans l'environnement et qui n'étaient pas connus lors de la conception de l'application. Par conséquent, nous avons opté pour une méthode de fusion ne nécessitant pas d'entraînement : un vote à la majorité ; nous avons testé quatre façons différentes pour effectuer ce vote à la majorité.

Nous avons tout d'abord réalisé un vote en prenant en compte la classe gagnante de chaque classifieur. Mais nous avons trouvé que cette méthode était limitée en précision car un classifieur qui ne serait pas satisfaisant sur la reconnaissance d'une classe d'activité donnée a autant de poids qu'un classifieur qui serait très bon pour cette même classe d'activité. En outre, comme nous ne prenons en compte qu'une seule classe (la meilleure pour chaque classifieur), nous perdons l'information dans le cas où un classifieur est hésitant (par exemple 51% pour la première classe et 49% pour une autre).

Pour surmonter ce problème, nous avons considéré le score obtenu par un classifieur pour chacune des classes (si un classifieur peut fournir ce type d'information bien entendu, ce qui n'est pas le cas de 1-NN par exemple). Avec ce nouveau mode de calcul, nous avons ainsi plus d'informations disponibles. Pour tenter d'obtenir encore plus de précision, nous avons pondéré les scores avec la précision globale du classifieur de telle sorte qu'un classifieur avec une mauvaise précision globale pèse moins d'un classifieur précis. Nous sommes finalement allés encore plus loin dans le réglage de la méthode de vote en pondérant chaque score, non pas avec la précision globale, mais avec la précision de la classe correspondante. En effet, un classifieur peut avoir une prédiction avec une bonne précision pour une classe, mais une mauvaise pour d'autres. L'utilisation de la précision pour chacune des classes a permis d'améliorer les résultats de la fusion de décisions. Les méthodes utilisant les scores pour effectuer la fusion sont décrites par les formules de la Figure 10.

$$class = class_of_max \left(\sum_{i=1}^n (c_{i,1}, c_{i,2}, \dots, c_{i,m}) \right)$$

$$class = class_of_max \left(\sum_{i=1}^n (c_{i,1}, c_{i,2}, \dots, c_{i,m}) \times a_i \right)$$

$$class = class_of_max \left(\sum_{i=1}^n (c_{i,1} \times a_{i,1}, c_{i,2} \times a_{i,2}, \dots, c_{i,m} \times a_{i,m}) \right)$$

n : number of classifiers in our combination
 m : number of classes we can recognize
 $a_{i,m}$: accuracy of the classifier i for the class m
 $c_{i,m}$: score of the classifier i for the class m

Figure 10: Formules pour les votes à la majorité

3.4 Résultats

La quatrième approche de vote à la majorité fournit les meilleurs résultats. Comme le montre la Figure 11, pour les capteurs utilisant la méthode d'apprentissage basée sur les Random Forests, nous avons les résultats les plus stables pour chacune des 13 configurations proposées dans le projet Opportunity. De plus, lorsque le nombre de capteurs dans la combinaison devient trop important (plus de 3 capteurs), la méthode 3-NN, qui a de moins bons résultats que la méthode RF pour les capteurs individuellement, en obtient de meilleurs.

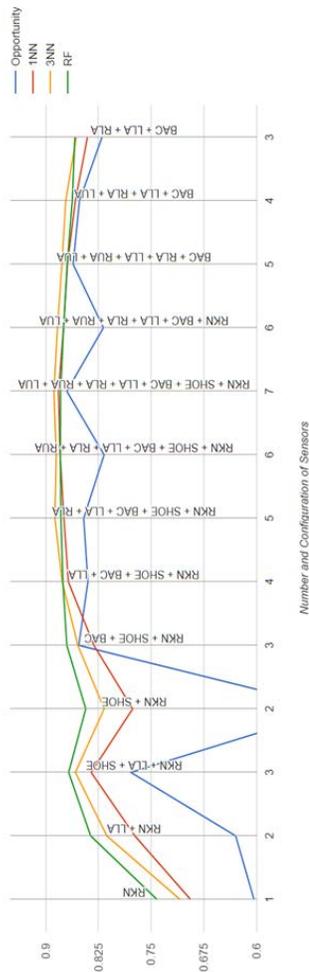


Figure 11: Précision dépendant du nombre et du type de capteurs entrant dans le calcul du résultat

Nous avons ensuite envisagé de tester, non seulement la fusion des décisions sur les treize combinaisons utilisées par le projet Opportunity, mais toutes les combinaisons possibles des 7 capteurs. Les résultats obtenus globalement sont en harmonie avec ceux obtenus sur le sous-ensemble utilisé par Opportunity, à savoir la méthode Random Forest donne de meilleurs résultats quand il y a moins de 4 capteurs dans la combinaison, puis la méthode 3-NN donne de meilleurs résultats pour un nombre de capteurs plus importants (Figure 12).

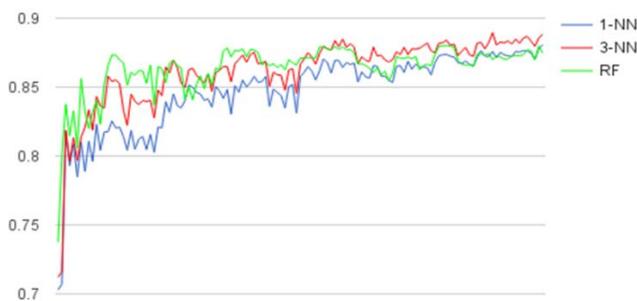


Figure 12: Précision pour toutes les combinaisons de capteurs en utilisant le vote à la majorité pondéré par classes

4. Travaux connexes

De nombreux travaux de recherche se concentrent sur la reconnaissance d'activités humaines à partir de données issues de capteurs. Par exemple, Banos et al. [2] expérimentent la reconnaissance d'activités à l'aide d'un jeu de données collectant les informations de 5 accéléromètres bi-axiaux. Ces travaux considèrent un faible nombre de capteurs, comme dans [5], [6], [3], [7], [8]. D'autres travaux considèrent un nombre plus important de capteurs. Par exemple, dans [8], le jeu de données utilisé pour la reconnaissance d'activités a été créé à partir des données issues de GPS et d'accéléromètres. Cependant, toutes ces études considèrent un ensemble de capteurs connus et fixes qui n'est pas sensé changer au cours du temps. Ces capteurs ont été utilisés dans le contexte de l'identification des comportements de voyage. Des capteurs ont aussi été utilisés dans un environnement hospitalier afin de permettre la localisation des patients dans l'hôpital [9]. Dans cet article, l'ensemble des données utilisé pour la reconnaissance de l'activité a été recueilli à partir d'un ensemble d'émetteurs et de récepteurs RFID connus. D'autres travaux utilisent les techniques basées sur le multi-objectif et l'utilisation de front de Pareto pour trouver des configurations optimales de composants [9].

Récemment, le projet européen Opportunity a adressé le problème de la reconnaissance d'activité humaine en utilisant un grand ensemble de capteurs (72 capteurs portés) [10], [11]. Une des contributions de ce projet a été de produire un jeu de données utilisé pour leurs expérimentations.

Ce jeu de données a aussi été utilisé dans un défi pour comparer différentes méthodes pour la reconnaissance d'activités. Dans [10], Chavarriga et al. ont obtenu de meilleurs résultats avec les méthodes des k plus proches voisins (« Nearest Neighbor » : 1-NN et 3-NN) par rapport aux méthodes Nearest Neighbor Classifier (NCC), Linear Discriminant Analysis (LDA) and Quadratic Discriminant Analysis (QDA). Néanmoins, ces résultats ont été obtenus pour un ensemble fixe de capteurs et les multi-classifieurs n'ont pas été considérés. Nos travaux améliorent les résultats obtenus dans le défi proposé par le projet Opportunity et améliorent aussi les résultats obtenus pour l'apprentissage individuel de chaque capteur en utilisant un multi-classifieur (Random Forest). Enfin, nous améliorons la précision des résultats en testant différentes méthodes de vote à la majorité.

5. Conclusion et travaux futurs

Dans cet article nous avons étudié les résultats présentés par le projet européen Opportunity avec différents types d'algorithmes d'apprentissage pour réaliser la reconnaissance d'activités humaines. Nous nous sommes placés dans un contexte similaire à celui proposé par le projet Opportunity en entraînant les capteurs individuellement à la reconnaissance et en combinant les décisions fournies par chacun des capteurs participant à la reconnaissance. Nous avons comparé les résultats que nous avons obtenus avec une approche à base de Random Forest aux meilleurs résultats obtenus par le défi Opportunity. Un multi-classifieur comme les Random Forests nous permet d'obtenir non seulement de meilleurs résultats individuellement pour chacun des capteurs, mais aussi une meilleure précision et une meilleure stabilité des résultats pour un petit nombre de capteurs.

Dans nos futurs travaux, nous étudierons la possibilité de combiner des classifieurs hétérogènes. En effet, avec l'apprentissage pour chaque capteur indépendamment, nous pouvons entraîner chacun d'eux avec des classifieurs spécifiques et adaptés afin d'obtenir les meilleurs résultats individuels et une meilleure fusion de décision. Nous allons également explorer d'autres méthodes de fusion des

décisions. Actuellement, le vote à la majorité pondérée ne dépend pas du nombre de capteurs, mais nous devons savoir combien de capteurs sont disponibles à un instant t pour pouvoir calculer la fusion des décisions. Nous travaillerons sur une méthode incrémentale pour améliorer ce travail.

6. REFERENCES

- [1] M. Kurz, G. Hözl, and A. Ferscha, 'Dynamic adaptation of opportunistic sensor configurations for continuous and accurate activity recognition', in *Fourth International Conference on Adaptive and Self-Adaptive Systems and Applications (ADAPTIVE)*, Nice, France, 2012.
- [2] J. Shotton, A. Fitzgibbon, M. Cook, T. Sharp, M. Finocchio, R. Moore, A. Kipman, and A. Blake, 'Real-time Human Pose Recognition in Parts from Single Depth Images', in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Washington, DC, USA, 2011, pp. 1297–1304.
- [3] K. Ellis, J. Kerr, S. Godbole, and G. Lanckriet, 'Multi-sensor Physical Activity Recognition in Free-living', in *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct Publication*, New York, NY, USA, 2014, pp. 431–440.
- [4] D. Roggen, A. Calatroni, M. Rossi, T. Holleczeck, K. Forster, G. Troster, P. Lukowicz, D. Bannach, G. Pirkl, A. Ferscha, J. Doppler, C. Holzmann, M. Kurz, G. Holl, R. Chavarriaga, H. Sagha, H. Bayati, M. Creatura, and J. del R Millan, 'Collecting complex activity datasets in highly rich networked sensor environments', in *Seventh International Conference on Networked Sensing Systems (INSS)*, 2010, pp. 233–240.
- [5] Y. Shi, Y. Shi, and X. Wang, 'Inertial Body-Worn Sensor Data Segmentation by Boosting Threshold-Based Detectors', in *2012 16th International Symposium on Wearable Computers (ISWC)*, 2012, pp. 114–115.
- [6] A. Reiss and D. Stricker, 'Introducing a New Benchmarked Dataset for Activity Monitoring', in *2012 16th International Symposium on Wearable Computers (ISWC)*, 2012, pp. 108–109.
- [7] J. A. Ward, P. Lukowicz, and H. W. Gellersen, 'Performance Metrics for Activity Recognition', *ACM Trans Intell Syst Technol*, vol. 2, no. 1, p. 6:1–6:23, Jan. 2011.
- [8] Y. Zheng, W.-K. Wong, X. Guan, and S. Trost, 'Physical Activity Recognition from Accelerometer Data Using a Multi-Scale Ensemble Method', in *Twenty-Fifth IAAI Conference*, 2013.
- [9] Z. W. Bhatti, N. Z. Naqvi, A. Ramakrishnan, D. Preuveneers, and Y. Berbers, 'Learning distributed deployment and configuration trade-offs for context-aware applications in Intelligent Environments', *J. Ambient Intell. Smart Environ.*, vol. 6, no. 5, pp. 541–559, 2014.