

Approche spatio-temporelle d'extraction de connaissances pour l'analyse du comportement humain à partir de séquences vidéo

[Spatio-temporal Approach for the Analysis of Human Behavior from Video Sequences]

Mikaël A. Mousse

Institut Universitaire de Technologie, Université de Parakou, Parakou, Benin

Copyright © 2023 ISSR Journals. This is an open access article distributed under the **Creative Commons Attribution License**, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

ABSTRACT: The analysis and exploration of traces of mobility produced by various mobile objects is a research topic that has attracted great interest in recent years. In this article, we present a classification (or clustering) approach adapted to the data of people moving under the constraints of a road network. A similarity measure is proposed to compare the trajectories studied with each other, taking into account the displacement constraints imposed by the network. This measurement is exploited to build a graph translating the different similarity relations maintained by the trajectories between them. We partition this graph using an algorithm using the notion of modularity as a quality criterion in order to discover communities (or clusters) of trajectories which are strongly linked and which exhibit a common behavior. We have implemented and tested the proposed approach on several synthetic datasets through which we show its operation.

KEYWORDS: knowledge extraction, point of interest, optical flow, decision tree, classification.

RESUME: L'analyse et la fouille des traces de mobilité produites par divers objets mobiles est un sujet de recherche qui sollicite un grand intérêt depuis quelques années. Dans le présent article, nous présentons une approche de classification (ou clustering) adaptée aux données de personnes se déplaçant sous contraintes d'un réseau routier. Une mesure de similarité est proposée pour comparer les trajectoires étudiées entre elles en tenant compte des contraintes de déplacement imposées par le réseau. Cette mesure est exploitée pour construire un graphe traduisant les différentes relations de similarité entretenues par les trajectoires entre elles. Nous partitionnons ce graphe à l'aide d'un algorithme utilisant la notion de modularité comme critère de qualité afin de découvrir des communautés (ou clusters) de trajectoires qui sont fortement liées et qui présentent un comportement commun. Nous avons implémenté et testé l'approche proposée sur plusieurs jeux de données synthétiques à travers lesquels nous montrons son fonctionnement.

MOTS-CLEFS: extraction de connaissances, point d'intérêt, flux optique, arbre de décision, classification.

1 INTRODUCTION

Nous vivons dans un monde plein de données (data) et ces dernières années nous assistons à une croissance importante des moyens de génération et de collection de ces données, le plus grand défi consiste non seulement à obtenir ces données mais également à les exploiter pour trouver de nouvelles et utiles connaissances à partir de cette mine de données. Face à cet intérêt, le domaine du data mining à émerger, et prend actuellement, une place très importante dans plusieurs domaines comme l'ingénierie, la vente-distribution marketing, l'informatique et l'économie etc. Cette importance évolue proportionnellement à nos besoins d'automatiser le processus d'extraction et de traitement de l'information. L'utilisation du data mining améliore grandement les performances des techniques d'analyse de données, afin d'offrir des modèles ou des informations utiles, compréhensibles et à jour. De plus, les techniques et les méthodes de fouille de données permettent aux organisations de tirer

plus d'informations à travers des modèles compréhensibles qui sont construits en utilisant des ensembles de données homogènes ou hétérogènes collectés de diverses sources de données comme la vidéo et les images. Cependant, dans la vie réelle, les données analysées deviennent de plus en plus compliquées et dynamiques (se modifient continuellement), comme les séries temporelles, les données à temps réel, les données satellitaires et les comportements d'individus. Ceci étant, atteindre les objectifs stratégiques qu'est de créer et livrer les meilleurs produits et services afin d'être plus compétitif sur le marché devient encore plus difficile pour les entreprises qui n'arrivent pas à pouvoir manipuler ces types de données. Ainsi notre attention s'est portée sur les supermarchés pour qui l'utilisation des données spatio-temporelles dans leur analyse leur permettra de: faire du marketing ciblé, fidéliser les clients, mieux satisfaire et servir les clients, donc d'être plus rentable. L'objectif de ce mémoire est de pouvoir construire des modèles descriptifs et prédictifs des comportements humains. Les modèles descriptifs peuvent être utilisés pour l'analyse temps-réel des comportements humains et les modèles prédictifs pour l'anticipation des comportements. En générale, notre but est d'aider les supermarchés, hypermarché, centre commercial et même les magasins à gérer toutes les phases du cycle de vie des clients, à augmenter les recettes provenant des clients existants, à conserver les bons clients et même à rechercher de nouveaux clients. Notre contribution apporte comme originalité l'analyse et l'apprentissage automatique de données spatio-temporelles liées aux comportements mais aussi les habitudes des clients pour la prise de décision.

2 TECHNIQUES D'EXTRACTION DE CONNAISSANCE

L'extraction de connaissances à partir de données aussi connues sous les noms fouille de données est un processus d'extraction de connaissances à partir de grands volumes de données. Cette extraction permet de détecter des règles dans ces données, des associations, des tendances inconnues et des structures particulières restituant de façon concise l'essentielle de l'information utile pour l'aide à la décision [9]. Il se propose d'utiliser un ensemble d'algorithmes issus de disciplines diverses (Statistique, intelligences artificielle, bases de données, recherche opérationnelle) pour construire un modèle à partir des données. Ces types de modèle sont intéressants, pour les décideurs, dans une entreprise telle que dans la gestion de stocks, dans les agences de voyage, dans le marketing ciblé, dans la compréhension du comportement des clients, dans l'assurance etc. Le Data Mining nécessite la connaissance du domaine pour décider quels genres de données doivent être utilisés ou quel genre d'information est la plus informative. De plus le travail de découverte de règles d'associations est itératif, l'analyste a besoin de reformuler des requêtes et d'ajuster les contraintes d'extraction pour trouver des règles intéressantes [9]. Nous distinguons cinq (05) techniques à savoir: la classification, le clustering, l'analyse des tendances, l'extraction de règles d'association et l'extraction de motifs séquentiels.

2.1 LA CLASSIFICATION

C'est la technique la plus usuelle qui définit les items dans des groupes connus. Il y a plusieurs outils pour la classification telle que les réseaux de neurones, les réseaux bayésiens, les arbres de décisions [9]. Parmi tous ces outils, les arbres de décision sont les plus utilisés parce qu'ils donnent une meilleure lisibilité de la classification. Nous dénombrons plusieurs outils pour la classification tel que les réseaux de neurones, les arbres de décisions, les réseaux bayésiens ici nous nous attarderons sur les deux premiers. Ces outils servent à utiliser des données, à regrouper ou relier les éléments qui se ressemblent et à séparer ceux qui diffèrent. Autrement dit à déterminer des profils de comportement, à découvrir des règles, à évaluer des risques [5].

2.2 LE CLUSTERING

Le Clustering est le fait de segmenter une population de données hétérogènes dans un nombre de sous-groupe (ou cluster en Anglais) beaucoup plus homogène. La différence principale entre la classification et le clustering est que la classification est totalement dépendante des classes déjà prédéfinis alors que le clustering ne l'est pas [9]. Avec le clustering, on ne connaît pas combien de groupes de classes existent auparavant, les données sont simplement regroupées en fonction des similarités. La détection automatique de clusters est une technique de découverte de connaissances non dirigée (ou apprentissage sans supervision). Chaque groupe représente un cluster. C'est une excellente technique pour démarrer un projet d'analyse ou de data mining. Les groupes de similitudes permettront de mieux comprendre les données et d'imaginer comment les utiliser au mieux [5]. L'analyse du panier de la ménagère est un moyen qui explique mieux le clustering de plus elle génère les règles et supporte l'analyse des séries temporelles (si les transactions ne sont pas anonymes). Les règles générées sont simples, faciles à comprendre et assorties d'une probabilité, ce qui en fait un outil agréable et directement exploitable par l'utilisateur métier.

2.3 L'ANALYSE DES TENDANCES

L'analyse des tendances est aussi appelée prédiction. Cette technique peut donc être utilisée pour la prédiction ou la classification mais généralement une simple observation du graphe permet de mener à bien l'analyse. Elle utilise les données du présent ou les données passées pour estimer les valeurs futures [9]. La plus populaires de ces méthodes est la régressions linaires utilisée pour interpoler et extrapoler des observations. Par exemple une entreprise peut utiliser son revenu annuel pour prédire celui de l'année prochaine.

2.4 L'EXTRACTION DES RÈGLES D'ASSOCIATIONS

Cette technique consiste aussi à relier des entités entre elles (clients, entreprises, etc.) par des liens. A chaque lien est affecté un poids, défini par l'analyse, qui quantifie la force de cette relation [5]. En effet Une règle d'association est de la forme, $A \rightarrow B$, où A et B sont un ensemble d'items, ce genre de règle signifie que les transactions contenant des items de A tendent à contenir des items de B. Pour qu'une règle d'association soit valide, le support (la fraction des transactions contenant tous les items dans l'union de A et de B) et la confiance (la probabilité mesurée comme les fractions de transactions contenant A contiennent aussi B) de la règle doivent satisfaire un seuil minimum fixé par l'analyste.

2.5 L'EXTRACTION DE MOTIFS SÉQUENTIELS

Ces genres de règles sont similaires aux règles d'associations mais les motifs séquentiels sont reliés à la notion de temps. Un exemple de motif connu est celui de la bière et des couches. Nous distinguons différents types de règles d'associations à savoir: les règles d'associations généralisées, quantitatives, sous contraintes, multidimensionnelles, intra-dimensionnelle, interdimensionnelle et hybrides.

Vu l'ampleur des travaux, plusieurs chercheurs se sont lancés dans les travaux exploitant les aspects spatiaux et temporelles dans la mise en place des algorithmes de fouilles de données.

2.6 FOUILLE DE DONNÉE SPATIALE

. Les données spatiales sont des données qui ont une composante spatiale ou de localisation. Elles peuvent être considérés comme des données sur des objets qui eux-mêmes ne sont pas situés dans un espace physique. Ceci peut être mis en œuvre avec un ou des attributs de localisation spécifiques tels que l'adresse ou la latitude / longitude qui peut être implicitement inclus. Les données stockées dans des bases de données spatiales contenant les données spatiales et non spatiales sur les objets sont requises pour de nombreux systèmes informatiques actuels. Les SIG sont utilisés pour stocker les informations géographiques liées à l'emplacement sur la surface terre. Cela inclut les applications liées à la météo, besoins en infrastructures communautaires, gestion des catastrophes et déchets dangereux. Les activités du DM comprennent la prévision des catastrophes environnementales. Les applications biomédicales, y compris l'imagerie médicale et le diagnostic des maladies nécessitent également des systèmes spatiaux [1]. De nouvelles techniques et algorithmes sont également développés spécifiquement pour l'exploration de données spatiales. Notons aussi que la simple visualisation des données sur une cartographie peut permettre la découverte de connaissances, cette découverte visuelle des connaissances peut être utilisée sur un volume de données limité mais elle doit être automatisée pour de grandes quantités de données. Cette automatisation est supportée par la fouille de données spatiales [11]. En effet Le domaine de la fouille de données spatiale s'intéresse à la découverte de modèles dans une base de données spatiales. La principale caractéristique de ce domaine est sa prise en compte de la dimension spatiale et des relations entre les objets [2]. Les objets étudiés sont des thèmes rassemblant les objets de même type. Ces thèmes ne sont rien d'autre que des tables avec un attribut de localisation où les interactions entre les objets sont représentées par des prédicats et des tables de distances. Selon Stephane Daviet [7], La dimension spatiale peut revêtir des caractéristiques variées suivant les domaines étudiant les données. Dans les SIG, les données sont principalement spatiales et peu dynamiques. Les systèmes développés pour traiter les données sont donc principalement axés sur la gestion de données spatiales. Pour l'étude de phénomènes mobiles (dynamique des fluides, étude de processus migratoires, suivi d'objets mobiles en temps réel), ces systèmes doivent également intégrer l'aspect dynamique des données et donc croiser les dimensions spatiales et temporelles. D'autre part, les objets étudiés peuvent eux-mêmes présenter des caractéristiques spatiales différentes, il peut s'agir de formes géométriques, d'objets ponctuels ou d'objets subissant des déformations au cours du temps (feu de forêt, fluide, solide déformable). Dans tous les cas précités, il s'agit d'étudier des données décrivant les trajectoires d'objet via leurs coordonnées dans l'espace. On peut également rencontrer les dimensions spatiales sous une forme sémantique où il s'agit de décrire les relations des objets les uns par rapport aux autres. Une position ne sera alors plus décrite par ses coordonnées mais par sa relation de voisinage par rapport

à un autre objet. D'une manière générale, si les recherches sur les données spatiales statiques ont fourni de nombreux résultats, c'est beaucoup moins le cas pour les données spatiales dynamiques.

2.7 FOUILLE DE DONNÉE TEMPORELLE

La fouille de données temporelles est un domaine relativement nouveau. Il est devenu plus populaire dans la dernière décennie en raison de la capacité accrue des systèmes informatiques modernes qui sont devenus capables de stocker et de traiter de grandes quantités de données de plus en plus complexes. Il n'est pas inhabituel de voir des équipements modernes générer des mégaoctets de données temporelles pendant leur surveillance constante des différents paramètres. Même une simple puce d'un capteur peut produire une quantité énorme d'informations temporelles, ce qui rend son analyse très difficile sans l'utilisation des techniques de la fouille de données temporelle [10]. Nous pouvons donc le définir comme la fouille de données avec la particularité de bien traiter les données temporelles. Conceptuellement, les données temporelles peuvent être classifiées en deux types différents: les séquences et les séries temporelles. Au niveau des séquences (ensemble ordonné d'événements souvent représentée par une série de symboles nominaux) les événements sont ordonnés dans le temps et se produisent séquentiellement, l'ajout du temps réel où l'évènement s'est produit, nous donne une séquence horodatée. Quant aux séries temporelles (séquence de valeurs continues d'éléments), elles agrandissent de façon spectaculaire les bases de données car des mesures prises par le capteur ainsi que le temps réel où les mesures étaient faites y sont renseignées, ce qui rend les techniques d'extraction de connaissances impraticables. Pour remédier à ce problème, la fouille de données temporelles effectue une transformation pour mieux présenter ces types de données. La difficulté de ces recherches réside dans les structures multiples avec lesquelles nous pouvons appréhender le temps. Le temps peut en effet être considéré comme linéaire, ramifié (ou hypothétique) ou cyclique. Dans le cas d'une structure ramifiée, on pourra avoir une ramification dans le futur (un seul passé, plusieurs futurs: ordre linéaire à gauche), dans le passé (plusieurs passés, un seul futur: ordre linéaire à droite) ou dans les 2 sens (aucun ordre). Le temps peut être fini ou non (Une structure cyclique n'a ni début, ni fin, donc un temps infini). Le temps peut être discret (entre deux instants t , il y a un nombre fini d'instant, temps isomorphe aux entiers), dense (entre deux instants t , il y a un nombre infini d'instant, isomorphe aux rationnels) ou continu (entre deux instants t , il y a un nombre infini d'instant, temps isomorphe aux réels). Enfin, on peut avoir une datation par points (le temps est représenté par une date) ou par intervalles (le temps est représenté par un intervalle de datation dont la durée peut être nulle). Mais dans notre cas, il s'agit d'une combinaison des deux types de DM développés jusque-là, découvrons donc ce qui en est du DM spatio-temporelle.

2.8 FOUILLE DE DONNÉES SPATIO-TEMPORELLES

Il existe une grande variété de données intégrant à la fois une dimension spatiale et temporelle. Ces données présentent toutefois des spécificités communes ayant un impact important sur l'analyse. L'intégration des dimensions spatiales et temporelles a mis en avant de nouvelles possibilités en termes d'analyse, mais cela a aussi introduit de nouveaux défis propres à ce type de données. Les dimensions spatiales et temporelles ont d'autres spécificités. Premièrement, elles sont souvent prépondérantes dans l'analyse par rapport aux autres dimensions. En effet, l'objectif est généralement d'étudier l'évolution dans l'espace et dans le temps d'objets ou de phénomènes. Deuxièmement, elles sont par nature continues. Par exemple, les déplacements de véhicules sont généralement représentés sur une carte, i.e. un espace continu à deux dimensions. Cette particularité a un impact important sur les méthodes d'extraction [12]. En effet, une grande partie d'entre elles considère des données discrètes. Un regroupement des valeurs est donc effectué (en prétraitement ou pendant l'analyse). L'influence de cette étape sur les résultats est très importante. Un exemple: deux événements pourront être perçus comme arrivant au même endroit et/ou au même moment (ou inversement) en fonction des regroupements effectués. Les données spatio-temporelles sont aussi caractérisées par différents types d'attributs: des attributs non spatio-temporels, des attributs temporels et des attributs spatiaux. Les deux premiers types d'attributs sont associés à des valeurs numériques ou nominales. Les attributs spatiaux sont différents, ils sont associés à des localisations, des zones, des périmètres ou des formes. Les méthodes d'extraction n'intègrent que très partiellement ces spécificités, et ceci malgré leur importance pour l'analyse. Prenons l'exemple d'une zone urbaine qui est naturellement appréhendée à différentes échelles tels que le bloc, le quartier, ou la ville. Cette relation hiérarchique peut exister pour d'autres types de données (données d'une entreprise). Toutefois, elle est plus importante dans le cadre des données spatio-temporelles car les dépendances spatiales et temporelles entre les observations peuvent beaucoup dépendre de l'échelle considérée. Une grande variété de données spatio-temporelles existe en fonction des objets étudiés, des contraintes d'acquisition et des problématiques. Dans cette optique nous avons les données liées à la mobilité relative aux déplacements, à la mobilité en général, et se présentent généralement sous la forme de bases de données de trajectoires (objet, temps, localisation), ensuite vient les données d'événements qui dans le cas d'une base de données d'événements est un ensemble de types d'objets (object-type) spatio-temporels. Chaque occurrence d'un type d'objets (ou évènements) est caractérisée par un tuple $(l; t; c; o; p)$ où l , est la localisation de l'objet spatial o (point, ligne ou polygone) de type c , et associé à l'ensemble de propriétés p , au temps t . Lorsque

les objets/événements ont une localisation fixe, ces données constituent des séries temporelles spatiales et peuvent être représentées par des séquences de valeurs associées à une localisation [12].

3 APPROCHE PROPOSÉE

Nous proposons ici une architecture à trois niveaux. De façon globale nous partons du flux vidéo pour arriver à l'analyse du comportement en passant par ces trois niveaux que sont : l'extraction, la modélisation des connaissances puis la classification. Rappelons que le champ d'étude ici est un supermarché. Tout d'abord, le flux vidéo est obtenu à l'aide d'une ou plusieurs caméras monoculaires statiques couvrant un champ ou un rayon donné, ensuite des méthodes de traitement tel que la soustraction de l'arrière-plan et le flux optique sont appliquées à ce flux vidéo pour permettre l'extraction des informations exploitables, qui seront modélisées en utilisant des algorithmes spécifiques de similitudes et de recherches de trajectoires spatio-temporelles pour qu'une classification de ces trajectoires soit faite afin de construire une base de connaissances qui permettra non seulement de prévoir mais aussi d'analyser le comportement des clients dans un supermarché. Notons que dans notre approche, chaque niveau se sert du résultat des niveaux précédent rendant de cette manière l'approche plus cohérente pour un meilleur résultat. La figure 1 présente l'architecture proposée.

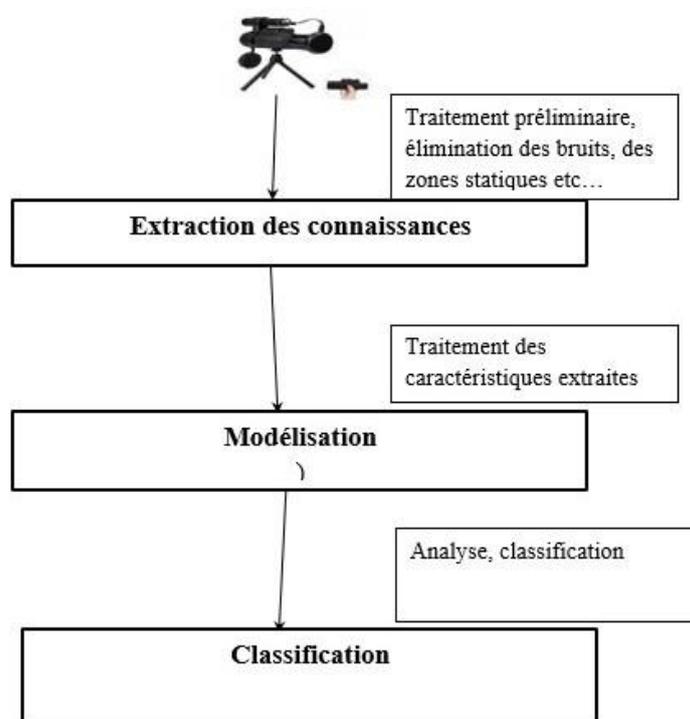


Fig. 1. Architecture proposée

3.1 EXTRACTION DES CONNAISSANCES

Dans un premier temps comme le montre la figure 1, la caméra envoie le flux vidéo issue de la zone couverte à un dispositif dont le rôle est de faire le prétraitement, permettant la détection, la séparation et le suivi des clients à travers la méthode des points d'intérêt après une soustraction d'arrière-plan (soustraction du modèle statique de l'arrière-plan), et l'utilisation des champs des vecteurs vitesses pour suivre les points d'intérêt dans des séquences d'images (flux optique).

Des réceptions de la séquence d'images, nous procédons à la conversion en noir et blanc des images (retrait des couleurs) et la soustraction de l'arrière-plan par détection de la région de mouvement en soustrayant pixel par pixel l'image courante à l'image de fond (image de base) pour la séparation des parties inutiles et indésirables, obtenant ainsi une meilleure utilisation des données, ensuite est utilisé un filtre basé sur le calcul du flot optique pour pouvoir suivre les objets détectés. Le principe consiste tout d'abord à déterminer le flot optique des points de Harris qui présentent une invariance en termes de translation, rotation et changement d'échelle. En supposant qu'il suit une distribution gaussienne dont les paramètres sont extraits du flot optique des points de Harris, le flot optique des autres pixels de l'objet est ensuite estimé par propagation du flot optique des points de Harris.

Le flot optique obtenu est enfin rectifié en utilisant un modèle de filtre de Kalman (qui regarde un objet quand il se déplace, c'est à dire il prend les informations sur l'état de l'objet à ce moment-là. Puis il utilise ces informations pour prédire où se trouve l'objet dans la prochaine trame. La position de l'objet est corrigée ensuite en considérant la prédiction et aussi l'observation) éliminant le bruit et/ou éléments externes indispensables. Les résultats du traitement préliminaires sont traitées suivant des caractéristiques d'extraction (chacune des caractéristiques extraites participent à la mise en place de la base de connaissance ainsi que l'analyse des habitudes des clients), telles que la date et l'heure (début et fin) du suivi du mouvement, le (s) rayon (s) visité (es), le temps effectués dans le (s) rayon (s), le nombre de personnes s'y trouvant, ainsi que le marquage des individus et/ou du groupe durant leur passage sans oublier les directions/trajectoires prises. Ces caractéristiques sont acquises respectivement à travers la date et heure de l'enregistrement ayant subi cette méthode d'extraction, l'identifiant des différentes caméras associé dès le départ à chaque séquence, la durée dans le temps de chaque trajectoire suivie, le nombre de trajectoire suivi dans chaque séquence et enfin la reconstitution des trajectoires. En sommes, l'enregistrement reçu des caméras donne comme informations, la date et heure de l'enregistrement, la durée, l'emplacement (la zone ou région) de la caméra ayant enregistré. Aux vues de tout ceci, voyons à présent comment les caractéristiques extraites sont utilisées pour la modélisation.

3.2 MODÉLISATION

La seconde étape qu'est la modélisation consiste à prendre les informations issues de l'extraction des connaissances pour en faire ressortir un modèle de connaissances. Notons que les caractéristiques extraites se présentent sous forme de coordonnées indiquant la ou les trajectoires suivies par les individus dans l'espace et dans le temps. La modélisation ou clustering est effectuée en post traitement sur un historique regroupant un nombre important de trajectoires. Il s'agira pour nous d'utiliser des algorithmes de similitude et de recherches de trajectoires pour le regroupement des individus en fonction des différentes trajectoires. Pour ce faire nous proposons de prendre ces trajectoires dans leur ensemble et y trouver les trajectoires similaires qui constitueront les clusters pour la base d'apprentissage. Les coordonnées ici ne seront donc pas sous la forme (x, y, t) ou (x, y) représente l'espace et t l'axe du temps mais plutôt sous la forme (Z_{id}, d, t) où Z_{id} est l'identifiant d'une zone, d est le décalage par rapport au point de départ de la zone et t le temps. Dans toutes sortes de requêtes, la valeur de Z_{id} doit être donnée. Notre approche est adaptée à celle du filtrage des trajectoires en fonction de la similitude spatiale et du raffinement trajectoires similaires basées sur la distance temporelle. Dans cette approche nous recherchons d'abord les trajectoires similaires pour ensuite procéder au regroupement construisant ainsi la base de connaissance exploitable pour la classification. La similitude de trajectoires se fait en deux étapes que sont: la similitude spatiale entre les trajectoires sur l'espace du supermarché et la distance temporelle entre les trajectoires temporelle pour un point d'intérêt (POI) ou un ensemble de POI. Notons que le POI ici est par exemple les intersections ou lieux importants du supermarché. La notion de similarité est effective lorsque deux trajectoires passent par les mêmes points d'intérêts. Supposons que P est un ensemble de POI, la similitude spatiale entre deux trajectoires T_a et T_b est définie par: $Sim_{POI}(T_a, T_b, P) = 1$ si quel que soit p appartenant à P , p est sur T_a et T_b sinon $Sim_{POI}(T_a, T_b, P) = 0$; L'aspect temporel est obtenu en calculant la distance temporelle entre les trajectoires. Chaque trajectoire est représenté par $t(T) = (t(T, p_1), t(T, p_2), \dots, t(T, p_k))$ où $t(T, p_i)$ représente le temps auquel la trajectoire passe par le point d'intérêt i . La distance temporelle entre deux trajectoires (T_a, T_b) pour un $i=1$ ensemble P de k points d'intérêts, est définie: $D_T = \sum_{i=1}^k |t(T_a, P_i) - t(T_b, P_i)|$ Une valeur seuil ϵ est définie pour évaluer la similarité entre les trajectoires.

Les trajectoires similaires étant représentées comme un point, nous avons toutes les trajectoires similaires à la suite de l'algorithme qui forme un cluster en fonction du décalage d et du temps, nous avons appliqué la méthode hiérarchique utilisant la technique agglomérative et l'approche *MIN* de calcul de similitude entre deux clusters.).

3.3 CLASSIFICATION

Cette dernière étape, est plus simple surtout lorsque le résultat de la modélisation nous permet déjà d'avoir un format de donnée ainsi qu'une base d'apprentissage cohérente. Il s'agira ici pour nous d'utiliser le principe de l'arbre de décision de par l'algorithme C4.5 afin de parcourir le dendrogramme de manière descendante et de classifier chaque cas. Les nœuds dans ce cas sont chaque point de cluster et les feuilles, les différents clusters de trajectoires similaires. On obtient l'algorithme III.1.

Algorithme III.1 Fonction de partition d'un algorithme de tri.

```

1  partition ( array , left , right )
2  nc := racine (D)
3  Compte :=nombre de noeud
4  Pour chaque nc de D faire
5  Suivre l'une des branches en fonction de l'instance dans nc et de sa valeur dans x.
6  Si nc = feuille alors
7  Le noeud atteint devient nc et la valeur x est classée.
8  Sinon
9  Si compte :=0 alors
10 Creer une nouvelle feuille
11 Sinon
12 compte :=compte-1
13 Finsi
14 FinSi
15 FinPour
16 retourner nc

```

Si $nc = \text{racine}(D)$ alors reprendre la méthode d'hierarchisation pour reconstruire le dendrogramme sinon passer au cas suivant et dérouler l'algorithme de classification (algorithme [III.1](#)).

4 RÉSULTATS ET DISCUSSIONS

L'algorithme proposé a été testé sur trois ensembles de données populaires: Weizman (source), KTH (source) et UCF (source). Ces ensembles de données sont choisis pour tester les performances de notre approche proposée sur les environnements contraints et non contraints avec différentes conditions.

Le jeu de données KTH est un jeu de données largement utilisé pour les évaluations des approches de reconnaissance d'action [3]. Les actions (confère Figure 2) ont été capturées avec une caméra statique dans un environnement contraint dans quatre scénarios différents: à l'intérieur, à l'extérieur, à l'extérieur avec des variations d'échelle et à l'extérieur avec des vêtements différents. Chaque vidéo est échantillonnée à 25 images par seconde avec une résolution de 160×120 pixels.

Le jeu de données Weizmann [4] contient 93 séquences vidéo (confère figure 3) montrant neuf acteurs différents, chacun exécutant dix actions: plier, sauter, sauter, sauter en avant sur deux jambes, sauter sur place sur deux jambes, galop de côté, agiter une main, agiter deux mains, courir et marcher. Ils ont une résolution spatiale de 180×144 pixels et sont capturés avec une caméra fixe à 25 images par seconde dans les mêmes conditions d'éclairage.

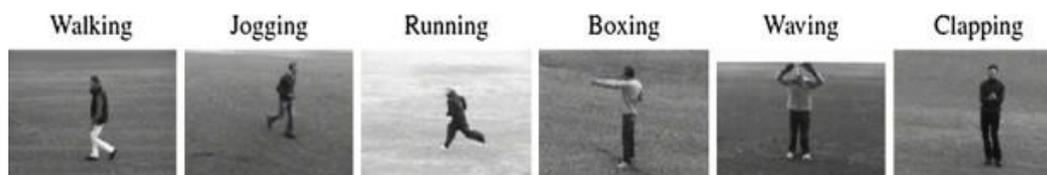


Fig. 2. Images de l'ensemble de données KTH

L'ensemble de données sportives de l'UCF [6] contient 150 échantillons vidéo pour dix types différents d'actions humaines dans les vidéos de diffusion sportive: plongée, élan de golf, coups de pied, haltérophilie, équitation, course, planche à roulettes, élan 1 (sur le cheval d'arçons et sol), se balancer 2 (aux barres hautes) et marcher (voir exemples sur la Figure 4). Les vidéos ont une fréquence d'images différente et une résolution d'image élevée. Nous suivons la configuration de Wang et al. [8], l'ensemble de données est étendu en ajoutant une version inversée horizontalement de chaque séquence à l'ensemble de données et chaque séquence est sous-échantillonnée à sa demi-résolution spatiale pour réduire les besoins élevés en mémoire.



Fig. 3. Images de l'ensemble de données Weizmann



Fig. 4. Images de l'ensemble de données Weizmann

Le tableau 1 présente les résultats de nos expérimentations.

	KTH	Weizmann	UCF sports
Algorithme proposé	94.9	96.66	89.97

D'après les résultats consignés de ce tableau, l'algorithme proposée a une performance de presque 90% pour le jeu de données UCF Sports. Cette performance passe à 94.9% si c'est le jeu de données KTH et à 96.7% pour le jeu de données Weizmann. De ces résultats, il est important de noter que l'approche proposée a des résultats compétitifs. La classification est fortement dépendante de la valeur du seuil d'appartenance à une classe. Ainsi les valeurs obtenues dans ce tableau sont les meilleurs obtenus après les différentes expérimentations. Il est nécessaire donc de trouver un algorithme qui permet de déterminer la valeur de seuil optimal pour les données manipulées. Les points d'intérêt spatio-temporels sont donc sélectionnés pour réduire la redondance et le niveau de bruit. D'autre part, la méthodologie de suivi est conçue pour extraire des trajectoires fiables et robustes capables de décrire les informations de mouvement sous les occlusions, les mouvements de la caméra, les changements de point de vue et les variations d'échelle.

5 CONCLUSION

En somme, l'algorithme de recherche de trajectoires de similitudes ayant pris en compte l'aspect spatiale dans un premier temps et l'aspect temporel dans un second temps a permis d'avoir un premier cluster spatio-temporel de trajectoires similaires. Ceci étant, l'apprentissage non supervisé utilisant la méthode hiérarchique a donc consisté à obtenir un dendrogramme des clusters qui sont plus proche compte tenu de la distance entre ces derniers formant ainsi la base de connaissance d'apprentissage. D'autre part, la méthodologie de suivi est conçue pour extraire des trajectoires fiables et robustes capables de décrire les informations de mouvement sous les occlusions, les mouvements de la caméra, les changements de point de vue et les variations d'échelle. Les expériences sont menées sur trois ensembles de données populaires (KTH, Weizmann et UCF sports). Ces expériences ont démontré la pertinence de l'approche proposée.

L'approche suggérée dans cet article se base sur un seuil pour effectuer la classification. Ainsi la valeur de seuil varie d'un jeu de données à un autre. Il est important de trouver un algorithme qui permet de trouver la valeur optimale pour le seuil en fonction de variable comme la taille des éléments de l'image et la densité des trajectoires.

REFERENCES

- [1] M. H. DUNHAM. *Data Mining: Introductory and Advanced Topics*. USA: Prentice Hall PTR, 2002. ISBN: 0130888923.
- [2] N. CHELGHOUIM et K. ZEITOUNI. « Mise en oeuvre des méthodes de fouille de données spatiales Alternatives et performances ». In: *EGC*. 2004.
- [3] C. SCHULDT, I. LAPTEV et B. CAPUTO. « Recognizing human actions: a local SVM approach ». In: *Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004*. Tome 3. IEEE. 2004, pages 32-36.
- [4] L. GORELICK, M. BLANK, E. SHECHTMAN, M. IRANI et R. BASRI. « Actions as spacetime shapes ». In: *IEEE transactions on pattern analysis and machine intelligence* 29.12 (2007), pages 2247-2253.
- [5] B. HOUMADI. « ÉTUDE EXPLORATOIRE D'OUTILS POUR LE DATA MINING ». In: jan. 2007.
- [6] M. D. RODRIGUEZ, J. AHMED et M. SHAH. « Action mach a spatio-temporal maximum average correlation height filter for action recognition ». In: *2008 IEEE conference on computer vision and pattern recognition*. IEEE. 2008, pages 1-8.
- [7] S. DAVIET. « Etude du comportement humain grâce à la simulation multi-agents et aux méthodes de fouille de données temporelles ». In: 2009.
- [8] H. WANG, M. M. ULLAH, A. KLASER, I. LAPTEV et C. SCHMID. « Evaluation of local spatio-temporal features for action recognition ». In: *Bmvc 2009-british machine vision conference*. BMVA Press. 2009, pages 124-1.
- [9] M. S. DIALLO, M. LO, C. DIOP et F. SANGARÃ©. « Etat de l'art sur ontologie et extraction de connaissance ». In: jan. 2011.
- [10] M. T. MOUTACALLI. « Une approche de reconnaissance d'activités utilisant la fouille de données temporelles ». In: 2012.
- [11] B. IDIRI. « Méthodologie d'extraction de connaissances spatio-temporelles par fouille de données pour l'analyse de comportements à risques: application à la surveillance maritime ». In: 2013.
- [12] F. FLOUVAT. « Extraction de motifs spatio-temporels: co-localisations, séquences et graphes dynamiques attribués. (Mining spatio-temporal patterns: colocations, sequences and dynamic attributed graphs) ». In: 2019.