



HAL
open science

Approche Bayésienne non-paramétrique pour la découverte de comportements émergents à partir de trajectoires

Guillaume Chiron, Petra Gomez-Krämer, Michel Ménard

► **To cite this version:**

Guillaume Chiron, Petra Gomez-Krämer, Michel Ménard. Approche Bayésienne non-paramétrique pour la découverte de comportements émergents à partir de trajectoires. Reconnaissance de formes et intelligence artificielle (RFIA) 2014, Jun 2014, France. hal-00988587

HAL Id: hal-00988587

<https://hal.science/hal-00988587>

Submitted on 8 May 2014

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Approche Bayésienne non-paramétrique pour la découverte de comportements émergents à partir de trajectoires

Guillaume Chiron¹

Petra Gomez-Krämer¹

Michel Ménard¹

¹ Laboratoire L3i, Université de la Rochelle, 17042 La Rochelle cedex 01

{guillaume.chiron, petra.gomez, michel.menard}@univ-lr.fr

Résumé

Cet article propose une approche Bayésienne non-paramétrique pour la découverte, à partir d'un ensemble structuré de trajectoires, de comportements émergents au sein d'une colonie d'insectes. L'analyse exploratoire des trajectoires issues de la scène encombrée s'effectue par classification non supervisée, simultanément sur des niveaux sémantiques différents, et où le nombre de clusters pour chaque niveau n'est pas défini a priori mais est estimé à partir des données. L'approche Bayésienne non-paramétrique s'appuie sur des processus de Dirichlet à mélange et conduit à la construction d'une hiérarchie sémantique. Pour la validation de notre approche, une pseudo-vérité terrain est générée à l'aide d'un Système Multi-Agents suivant l'algorithme des abeilles. L'intérêt de cette approche est, pour gagner en robustesse, l'apport d'un minimum d'a priori aussi bien au niveau des trajectoires simulées, sans modèles formels, qu'au niveau de la modélisation elle-même. La capacité de notre approche pour découvrir des comportements émergents de niveaux sémantiques différents est montrée expérimentalement.

Mots Clef

Comportement, scène encombrée, trajectoires, processus de Dirichlet hiérarchique, système multi-agents

Abstract

This paper proposes a non-parametric Bayesian approach to discover emergent behaviors in insect colonies from a structured trajectory set. The crowded scene is modeled by a multi-layer Hierarchical Dirichlet Process working on 3 semantic levels : activity atoms, activities and behaviors. Concerning the validation, a ground truth has been generated using a Multi-Agent System (bee colony algorithm) The strength of this approach is the injection of a minimum of a priori into the simulated tracks, as well as into the modelisation. The experimentation results have shown the efficiency of our approach to discover emergent behaviors at different levels.

Keywords

Behaviors, crowded scenes, trajectories, hierarchical Dirichlet process, multi-agent systems

1 Introduction

La recherche d'information sémantique, sur des scènes compliquées voire encombrées, est un sujet de recherche actif, qui intéresse de plus en plus les biologistes. Aujourd'hui, la communauté Vision et Analyse des Comportements des Insectes et Animaux (VACIA) s'attaque à des problèmes tels que la modélisation du comportement d'un essaim ou la modélisation de l'activité de colonies à partir de vidéos. Contrairement aux scènes encombrées fréquemment rencontrées en video-surveillance (ex : trafic, piétons), les insectes produisent des scènes bien moins structurées, et bien moins délimitées par des contraintes environnementales (ex : murs, couloirs, routes). Parfois même, les cibles ne suivent aucune tendance de mouvement perceptible.

La récente démocratisation des caméras RGB-D offre des possibilités intéressantes en termes de suivi de trajectoires dans une colonie d'insectes [1] ou d'essaims [2]. Considérant une chaîne de traitement type (acquisition, segmentation, suivi de cibles, analyse comportementale), cet article porte essentiellement sur la dernière étape. L'objectif de ce travail est de proposer une approche permettant la découverte de comportements émergents à partir d'un ensemble structuré de trajectoires non-contraintes, avec un minimum d'a priori sur le modèle. Les approches Bayésiennes non-paramétriques à base de Processus de Dirichlet Hiérarchiques ou HDP pour Hierarchical Dirichlet Process ont récemment montré leur efficacité en termes de modélisation comportementale de scènes encombrées. Dans ce contexte, les applications s'appuient en général sur le mouvement global (voir Section 1.1). A l'inverse, nous proposons de travailler à partir de trajectoires individuelles (séquences de points).

Notre jeu de données contient un ensemble de trajectoires extraites à partir d'une vidéo, structurée en captures et sous-clips vidéos. Une méthode de clustering s'appuyant sur un HDP multi-niveaux (MLC-HDP pour Multi-Level Clustering Hierarchical Dirichlet Process) permet de détecter et regrouper les événements notables selon différents niveaux. Ensuite, les captures et les sous-clips, selon leur niveau respectif, sont étiquetés en fonction des événements les plus représentatifs. Notre modèle est constitué des trois niveaux sémantiques suivants : comportement, activité, et

atome d'activité. Des concepts similaires ont été présentés dans [3] avec un double-HDP, et dans [4] avec l'approche MLC-HDP dans le cadre d'une application médicale.

Concernant les insectes, il n'existe pas à notre connaissance aujourd'hui de vérité terrain au niveau comportemental. Aussi, nous proposons une méthode originale pour valider notre approche. Celle-ci repose sur un Système Multi-Agents (SMA) mettant en oeuvre un algorithme de colonies d'abeille pour générer des comportements et des trajectoires associés. Cette méthode de simulation ne contraint pas les trajectoires par un modèle de dynamique, et permet donc d'injecter un minimum d'a priori dans l'analyse exploratoire. La Figure 1 illustre l'approche conjointe «simulation SMA / modélisation MLC-HDP». Le codage associant respectivement les cercles colorés et les carrés aux comportements et aux activités sera conservé dans la suite de cet article.

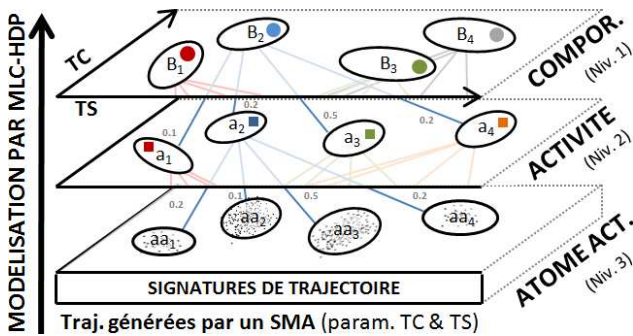


FIGURE 1 – Approche conjointe «simulation SMA / modélisation MLC-HDP». Le MLC-HDP regroupe les trajectoires sur chaque niveau sémantique. Les paramètres TC & TS sont définis dans la Section 3.

Cet article présente donc une approche originale s'appuyant sur un minimum d'a priori pour la découverte de comportements émergents à partir d'un ensemble structuré de trajectoires. Les contributions sont les suivantes :

- l'utilisation d'un HDP multi-couches pour la découverte de comportements émergents. A notre connaissance, les approches similaires en relation avec la modélisation comportementale, utilisent au maximum 2 couches ;
- l'utilisation de caractéristiques extraites à partir des trajectoires individuelles, plutôt qu'une approche fondée sur le flot optique tel que traditionnellement utilisé pour les scènes encombrées ;
- la validation originale par une simulation SMA, fournissant indirectement la vérité terrain sémantique associée au jeu de données.

Tout d'abord, la Section 1.1 propose un bref état de l'art. Puis, la Section 2 introduit notre approche fondée sur MLC-HDP et détaille les caractéristiques extraites des trajectoires. Ensuite, la Section 3 valide notre approche via un SMA. Finalement, la Section 4 conclut ce travail avec un certain nombre de perspectives.

1.1 Etat de l'art et travaux relatifs à l'étude

Une première approche, largement étudiée au sein de la communauté VACIA repose sur le regroupement de trajectoires individuelles en fonction des signatures reposant sur des caractéristiques locales. Par exemple, dans [5], sont classées des trajectoires 2D d'abeilles à partir d'un Modèle de Markov Caché (MMC). Dans [6], est présentée une méthode de classification hiérarchique pour identifier la caractéristique normale ou anormale de trajectoires de poissons. Certaines méthodes telles que [7] et [8] combinent l'analyse comportementale au suivi afin d'améliorer l'efficacité de ce dernier.

Une seconde approche orientée modélisation d'essaims est également étudiée. En général, les scènes encombrées, de par leur nature, sont plutôt étudiées en s'appuyant sur le mouvement général. Par exemple, dans [9] est utilisé un classifieur de type «sac de mots» basé sur des caractéristiques issues d'un calcul de flot optique sur des données éparpillées pour la détection et la localisation d'activités anormales au sein d'une foule. Dans [10], un MMC combiné à une méthode de clustering spectral est utilisée pour la détection d'atroupements. Une étude du comportement général de la scène, caractérisée par un modèle de variations du mouvement au sein de volumes spatio-temporels est proposée dans [11].

Cependant, les scènes de type «colonie» ou «essaim» ont été relativement peu étudiées en termes d'analyse comportementale, notamment en raison de la petite taille, de la rapidité et de la nature chaotique de la dynamique des cibles. Les approches classiques de type flot optique ont montré leurs limites. Récemment, des articles tels que [2], [12], et [1] ont proposé des méthodes de suivi de cibles pour les insectes en mettant à profit la disponibilité sur le marché de nouveaux types de caméra, qui ont ouvert des perspectives intéressantes en terme de modélisation comportementale.

Les modèles Bayésien hiérarchiques fournissent une solution attractive pour la modélisation d'activité chaotique. Le HDP originalement proposé dans [13], est une approche Bayésienne non-paramétrique permettant de clusteriser un jeu de données à différentes échelles, tout en partageant l'information au travers d'une hiérarchie. Des approches similaires ont été largement utilisées par la communauté document (analyse documents/thème). Récemment, ces approches HDP ont montré leur efficacité pour regrouper des données structurées dans d'autres domaines applicatifs. Par exemple, le double-HDP présenté dans [3] permet de détecter des activités co-occurentes dans une vidéo via un mécanisme de clustering croisé de fragments d'activités issues de sous-clips. Dans le domaine médical, dans [14], des tractographies (données proches des trajectoires) sont segmentées grâce à un modèle de mélange de HDPs. Finalement, dans [4], une distribution de clustering est calculée sur un modèle infini de mélange via une approche HDP multi-couches (qui est une autre extension du HDP). Elle conduit à un regroupement des électroencéphalographies sur différents niveaux.

2 Approche proposée

Cette section détaille notre approche s'appuyant sur une méthode Bayésienne non-paramétrique pour la découverte de comportements émergents à partir de trajectoires : le Processus de Dirichlet Hiérarchiques avec un clustering sur plusieurs niveaux (MLC-HDP). Cette section est organisée en 4 parties : 1) la structure des données utilisées, 2) les caractéristiques extraites, 3) un rappel sur le processus de Dirichlet et 4) l'utilisation du MLC-HDP adapté à notre problème.

2.1 Structure de données

Le jeu de données utilisé dans notre approche est structuré sous la forme d'un ensemble de captures. Les captures correspondent à une même scène filmée par une caméra fixe à différents instants (ex : heures, jours, semaines). Nous ne traitons pas, dans cet article, le problème du calcul des trajectoires (cf. [1]). Ainsi nous considérons par la suite une capture comme des ensembles de trajectoires (séquence de points) ordonnées dans le temps. Les captures sont segmentées en sous-clips à l'aide d'une fenêtre glissante non-chevauchante (ex : 5 sec). La taille de la fenêtre doit être assez grande pour assurer un nombre suffisant de trajectoires dans chaque sous-clip, mais doit aussi être de taille raisonnable pour éviter que les sous-clips contiennent plusieurs activités. Le concept d'activité sera défini par la suite à l'aide d'exemples. Finalement, le jeu de données est constitué de nombreuses trajectoires structurées en captures et sous-clips suivant une granularité donnée. La Figure 2 illustre un exemple de jeu structuré de données.




FIGURE 2 – Exemple de jeu structuré de données.

2.2 Extraction des caractéristiques

Le choix des caractéristiques extraites des trajectoires est bien sûr primordial pour la qualité des résultats. Par exemple, dans [6], les auteurs représentent une trajectoire de poisson par 179 caractéristiques (originellement 776 caractéristiques extraites, réduites par Analyse de Composantes Principales (ACP)). Notre approche s'inspire de ces travaux, notamment en considérant un mélange de caractéristiques locales et globales (caractérisant la trajectoire par rapport à l'environnement). En pratique, les trajectoires d'êtres vivants sont souvent chaotiques et suivent difficilement un modèle définissable. Cela explique la nécessité d'avoir recours à un grand nombre de caractéristiques. Étant donné que notre objectif s'intéresse à la détection d'événements notables plutôt qu'à la détection de

trajectoires anormales, un nombre restreint de caractéristiques s'avère suffisant. Pour chaque trajectoire, un vecteur constitué de caractéristiques décrites ci-après est extrait. Il représente la trajectoire par un point dans \mathbb{R}^d . Les vecteurs sont normalisés sur chacune de leurs dimensions.

Caractéristiques locales invariantes : La Fonction de Distance Centrée (CFD) mentionnée dans [15] consiste à calculer la distance relative entre chaque point de la trajectoire et son centroïde, défini par $c(i) = \sqrt{(x(i) - \bar{x})^2 + (y(i) - \bar{y})^2}$ avec i l'index du point de la trajectoire. Les 7 caractéristiques suivantes sont extraites à partir du vecteur c : la moyenne, l'écart-type, le minimum, le maximum, l'asymétrie, le coefficient d'aplatissement et le nombre de croisements à la moyenne (en analogie avec le concept de «zero-crossing»).

Caractéristiques globales : Si l'on considère le cas en deux dimensions, la scène peut être représentée par une grille de n lignes sur m colonnes. Un vecteur de caractéristiques de $n \times m$ valeurs, correspondant au temps passé par la cible dans chaque cellule de la grille utilisée. Une ACP est appliquée afin de réduire le nombre de dimensions, tout en veillant à garder au moins 90% de l'information.

2.3 Processus de Dirichlet (DP)

Le DP est utilisé comme un prior pour échantillonner des mesures de probabilité. Il est défini par un paramètre de concentration α , un scalaire positif, et la distribution de base H . Il est à noter que le paramètre de concentration a un impact significatif sur le nombre de clusters obtenus. Une mesure de probabilité G tirée aléatoirement par un Processus de Dirichlet $DP(\alpha, H)$ est toujours une distribution discrète, même si H est continue : $G = \sum_{k=1}^{\infty} \pi_k \delta_{\phi_k}$ peut être obtenue grâce au modèle du bâton cassé (stick-breaking). Dans ce contexte de modèles de mélange, une mesure aléatoire discrète distribuée par une DP est utilisée comme prior sur les paramètres de composantes de mélange.

$$\begin{aligned} G &\sim DP(\alpha, H) \\ \theta_i | G &\sim G \\ x_i | \theta_i &\sim F(\theta_i) \end{aligned}$$

avec $\{x_i\}$ les variables observées à modéliser, θ_i les paramètres de la composante de mélange à laquelle x_i appartient (ex : moyenne et variance unitaire d'une composante de Gaussienne), F la distribution de composantes de mélange (ex : Gaussienne dans une mélange de Gaussienne).

2.4 HDP avec du Clustering Multi-Couches

Le MLC-HDP a été originalement proposé par D. Wulsin dans le cadre d'une application médicale [4]. Nous avons adapté cette méthode à notre problème d'analyse exploratoire à partir de trajectoires. La Figure 3 illustre les deux extensions (HDP [13] et MLC-HDP) qui ont été successivement ajoutées au DP classique. Par rapport au DP classique, le HDP ajoute le partage des clusters sur les différents groupes de données. Le HDP correspond à la première couche du MLC-HDP, qui permet en plus de cluste-

riser les données sur plusieurs couches de manière hiérarchique. Comme le montre la Figure 1, notre approche est construite autour des trois niveaux sémantiques décrits ci-après, où chacun est associé à un élément de la structure du jeu de données. Ci-dessous des exemples d'événements relatifs à notre jeu de données sur les abeilles décrit en Section 3.

Niv. 1 - Comportement : Un comportement est représenté par un ensemble de poids sur toutes les activités. Un comportement est associé à chaque capture e.g. collecte de nourriture source par source, pas de collecte.

Niv. 2 - Activité : Une activité est représentée par un ensemble de poids sur tout atome d'activité. Une activité est associée à chaque sous-clip e.g. collecte de nourriture sur la source s , déploiement à partir de s .

Niv. 3 - Atome d'activité : Un atome d'activité est un cluster de trajectoires similaires, selon les caractéristiques extrinsèques. e.g. abeilles volant dans la même direction.




FIGURE 3 – Exemples de clustering avec DP, HDP and MLC-HDP sur un jeu de données structuré simple.

De manière formelle, nous considérons un jeu de données constitué de T captures, où chaque capture t est composée de J_t sous-clips, et où chaque sous-clip j est composé de N_{tji} signatures de trajectoires, que nous nommons $x_{tji} \in \mathbb{R}^d$. La variable d représente la dimension spatiale des signatures.

L'observation $\{\{\{x_{tji}\}_{i=1}^{N_{tj}}\}_{j=1}^{J_t}\}_{t=1}^T$ de toutes les trajectoires est modélisée par un ensemble de distributions de base unique d'atomes avec une distribution de base H et des paramètres λ pour une distribution arbitraire $x_{tji} \sim F(\theta_{tji})$ où θ_{tji} sont les paramètres du modèle, qui correspondent à l'atome ϕ_k au niveau le plus bas. Nous considérons F comme une distribution normale multivariée avec une matrice de covariance diagonale. Les trois niveaux du MLC-HDP sont définis par :

Level 1 : Comportement	Level 2 : Activité
$\beta^{(1)} \sim GEM(\gamma^{(1)})$	$\beta^{(2)} \sim GEM(\gamma^{(2)})$
$\pi^{(1)} \sim DP(\alpha^{(1)}, \beta^{(1)})$	$\pi_l^{(2)} \sim DP(\alpha^{(2)}, \beta^{(2)})$
$z_t^{(1)} \sim \pi^{(1)}$	$z_{tj}^{(2)} \sim \pi_{l=z_t^{(1)}}^{(2)}$
Level 3 : Atome d'activité	Trajectoires (signatures)
$\beta^{(3)} \sim GEM(\gamma^{(3)})$	$\phi_k \sim H(\lambda)$
$\pi_\ell^{(3)} \sim DP(\alpha^{(3)}, \beta^{(3)})$	$x_{tji} \sim F(\phi_{k=z_{tji}^{(3)}})$
$z_{tji}^{(3)} \sim \pi_{\ell=z_{tj}^{(2)}}^{(3)}$	

où GEM fait référence à la distribution de Griffiths-Engen-McCloskey. Le paramètre d'intensité α régule le nombre de pics. Plus de détails sur le MLC-HDP sont donnés dans [4]. En addition, afin de clarifier le lien entre le modèle et le jeu de données, le mécanisme d'inférence doit être abordé. La Figure 4 montre comment le jeu de données structuré est lié aux différentes couches du modèle.

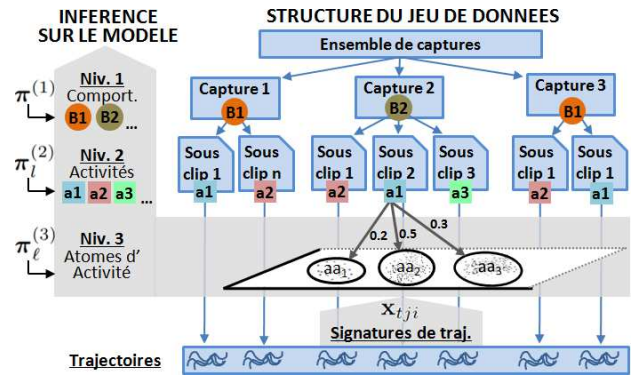


FIGURE 4 – Mécanisme d'inférence des paramètres du modèle à partir des données. En descendant, les boîtes bleues montrent la structure du jeu de données. En montant, les flèches grises représentent la modélisation étape par étape des données jusqu'au niveau du comportement.

3 Validation

Dans cette section, nous validons notre approche en appliquant le MLC-HDP sur des trajectoires d'abeilles générées par un SMA. L'avantage de la validation par un SMA est double. Premièrement, les SMAs permettent de simuler des comportements variés via des modèles simples comportant peu de paramètres. Deuxièmement, les trajectoires simulées ne sont pas directement contraintes par un modèle de trajectoire défini. L'aspect intéressant est que les deux approches (simulation et modélisation) sont utilisées avec un minimum d'a priori. Les comportements du SMA peuvent alors être observés sur la couche la plus haute du modèle. Nous avons implémenté un modèle de SMA simulant des abeilles à la recherche de nourriture souffrant d'une possible intoxication (détails de l'algorithme dans «matériel supplémentaire», inspiré des règles énoncées dans [16]). Ce modèle est configurable via les paramètres suivants : l'environnement (position de la ruche et des différentes sources de nourriture), la population, le taux de communication (TC) entre les abeilles au niveau de la ruche, et le

taux de sensibilité (TS) des abeilles vis à vis des sources de nourriture rencontrées. La Figure 5 illustre les simulations sous 4 configurations différentes. L'effet des paramètres TC et TS est clairement observé sur les graphiques des sources de nourriture. Les cas B (TC élevé, TS faible), C (TC et TS élevé) et D (TC et TS élevé) conduisent les abeilles à récolter les sources de nourriture simultanément, mais à des vitesses différentes. A l'opposé, dans le cas A (TR haut, TS faible) les sources sont récoltées une à une.

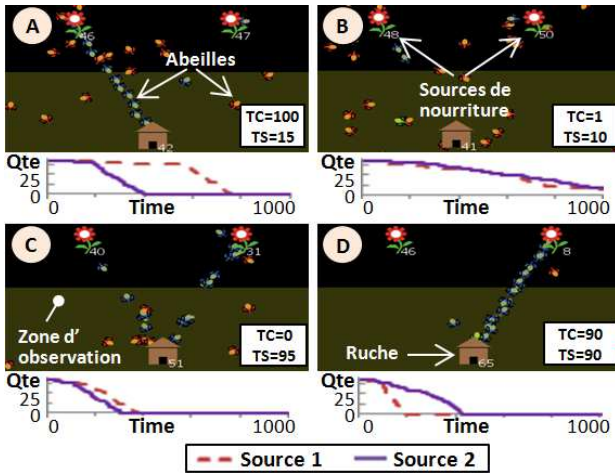


FIGURE 5 – Simulations de l'algorithme des abeilles selon 4 configurations, chacune illustrée par une vue Netlogo (150ème itération) en haut, et un graphique des sources de nourriture en bas.

Le SMA anime un nombre fixe d'agents dans un monde bouclé horizontalement et verticalement. A partir de ces agents, les trajectoires sont collectées et rassemblées dans un jeu de données. Durant la simulation, chaque agent produit un nombre variable de trajectoires. Une trajectoire est considérée dans la zone d'observation lorsqu'un agent la traverse ou lorsqu'il atteint la ruche. Les trajectoires mesurent en moyenne 23 points (1 point par unité de temps). Un couple «vue Netlogo» et «graphique de nourriture» (cf. Figure 5) constitue notre vérité terrain correspondant à la couche «activité» du MLC-HDP (niveau 2). De plus, les paramètres (TC et TS) donnent des indications que l'on peut lier à la couche «comportement» du MLC-HDP (niveau 1).

3.1 MLC-HDP sur une simple capture

Cette section illustre l'utilisation du MLC-HDP sur une seule capture. La capture dure 1000 itérations (ou unités de temps), est segmentée en 31 sous-clips, et comporte en tout 1151 trajectoires. Etant donné que cette expérience concerne seulement une capture, les résultats présentés (cf. Figure 6) correspondent à la couche «activité» du MLC-HDP (niveau 2). Dans cet exemple, les paramètres suivants ont été utilisés pour la simulation SMA : TC=80, TS=80, trois sources de nourriture à égale distance de la ruche. Les graphiques d'évolution des sources de nourriture montrent que les sources de nourriture ont été récoltées une à une.

Chaque sous-clip a été associé à une des 7 activités distinctes trouvées par le MLC-HDP. Ces 7 activités sont modélisées grâce à 9 atomes d'activité associés à différents poids. L'atome d'activité le moins et le plus représenté a été associé respectivement à 78 et 313 trajectoires. Comme le montre la Figure 6, la plupart des transitions entre activités peuvent être associées à des événements notables qui se sont passés lors de la simulation. Nous avons associé 5 interprétations aux séries d'activités trouvées par le MLC-HDP (ex : récolte des sources, exploration). Selon la granularité du jeu de données, les événements notables peuvent se mélanger ou se séparer, et donner naissance à des activités de natures différentes.




FIGURE 6 – Résultat sur 1 capture, avec les correspondances (au centre) entre la simulation (en haut) et la modélisation (en bas). Chaque carré montre, par sa couleur, l'activité correspondant au sous-clip associé.

3.2 MLC-HDP sur plusieurs captures

Cette section illustre l'utilisation du MLC-HDP sur plusieurs captures. Contrairement à l'utilisation d'une seule capture, les résultats suivants se focalisent essentiellement sur la couche «comportement» du MLC-HDP. Néanmoins, le succès du clustering au plus haut niveau sémantique témoigne du bon fonctionnement des couches inférieures. Dans cette expérience, les 4 comportements présentés précédemment (cf. Figure 5) sont mis en oeuvre. Chacun des 4 comportements sont simulés 5 fois, ce qui correspond à un jeu de données constitué de 20 captures. L'environnement (2 sources de nourritures) et la population (100 abeilles) sont gardés stables pour l'ensemble des captures. Le jeu de données est alors composé de 27789 trajectoires séparées en 20 captures, elles-mêmes segmentées en 16 sous-clips. La Figure 7 montre les résultats du clustering (couche «activité» et «comportement»). La double force du MLC-HDP est clairement visible. Premièrement, 4 catégories principales ont été trouvées avec un minimum d'a priori. Deuxièmement, 19 sur 20 captures ont été correctement classées en adéquation avec les paramètres de simulation. La seule erreur de classement peut s'expliquer par la nature aléatoire de la simulation SMA, qui peut parfois conduire à des comportements à la limite de ceux trouvés par le modèle MLC-HDP. La couche «activité» montre la séquence d'activités, qui correspond à l'évolution temporelle de la colonie. Il est intéressant de noter que l'aspect temporel n'est pas pris en compte avec le MLC-HDP. Par exemple, le comportement «Récolte des sources une à une» est similaire, peu importe l'ordre de récolte des sources.

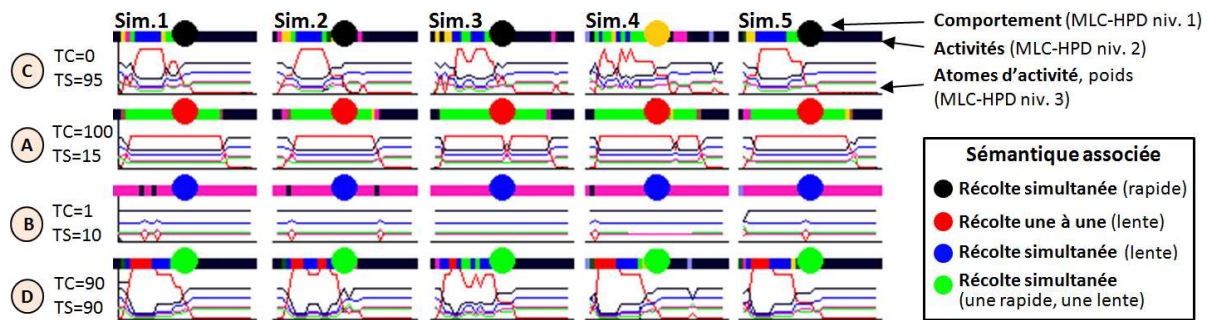


FIGURE 7 – Résultats sur 20 captures, chacune composée de plus de 1000 trajectoires. 4 configurations sont testées, avec 5 simulations pour chaque configuration afin d’assurer une certaine robustesse.

4 Conclusion

Cet article propose une approche pour la découverte de comportements émergents à partir d’un ensemble structuré de trajectoires à différentes échelles. La modélisation MLC-HDP et la validation par une simulation SMA ont tous les deux répondu à la contrainte de travailler avec un minimum d’a priori. Deux expériences au niveau «activité» et au niveau «comportement» ont confirmé l’efficacité de notre approche à différentes échelles. La première expérience montre des résultats en cohérence avec le graphique d’évolution des sources de nourriture, où les transitions entre différentes activités ont pu clairement être identifiées et même interprétées grâce à la vérité terrain. La seconde expérience a démontré la capacité du MLC-HDP à approximer le nombre de comportements types et à classifier de manière satisfaisante les captures parmi ces comportements avec un minimum d’a priori.

Notre équipe travaille en ce moment sur la construction d’un jeu de données constitué de trajectoires 3D d’abeilles ([1]) issues de capture réelles, et prévoit d’utiliser le MLC-HDP pour analyser les comportements. Concernant la méthode, il serait intéressant d’ajouter le concept de Modèle de Markov Caché sur la couche de plus haut niveau pour modéliser l’aspect temporel du jeu de données.

Références

- [1] G. Chiron, P. Gomez-Krämer, and M. Ménard, “Detecting and tracking honeybees in 3D at the beehive entrance using stereo vision,” *EURASIP Journal on Image and Video Processing*, no. 1, p. 59, 2013.
- [2] D. Theriault, Z. Wu, N. Hristov, and al, “Reconstruction and analysis of 3D trajectories of Brazilian free-tailed bats in flight,” Boston Univ., Tech. Rep., 2010.
- [3] X. Wang, X. Ma, and W. E. L. Grimson, “Unsupervised activity perception in crowded and complicated scenes using hierarchical bayesian models,” *IEEE, PAMI*, vol. 31, no. 3, pp. 539–555, 2009.
- [4] D. Wulsin, S. Jensen, and B. Litt, “A hierarchical Dirichlet process model with multiple levels of clustering for human EEG seizure modeling,” in *29th ICML*, 2012.
- [5] A. Feldman and T. Balch, “Representing honey bee behavior for recognition using human trainable models,” *Adaptive Behavior*, vol. 12, no. 3, p. 241, 2004.
- [6] C. Beyan and R. B. Fisher, “Detection of abnormal fish trajectories using a clustering based hierarchical classifier,” in *BMVC, Bristol, UK*, 2013.
- [7] A. Veeraghavan, R. Chellappa, and M. Srinivasan, “Shape-and-behavior encoded tracking of bee dances,” *IEEE, PAMI*, vol. 30, no. 3, p. 463, 2008.
- [8] J. Campbell, L. Mummert, and R. Sukthankar, “Video monitoring of honey bee colonies at the hive entrance,” *VAIB in conjunction with ICPR*, 2008.
- [9] R. Mehran, A. Oyama, and M. Shah, “Abnormal crowd behavior detection using social force model,” in *CVPR. IEEE*, 2009, pp. 935–942.
- [10] E. L. Andrade, S. Blunsden, and R. B. Fisher, “Modelling crowd scenes for event detection,” in *Pattern Recognition, 2006. ICPR 2006. 18th International Conference on*, vol. 1. IEEE, 2006, pp. 175–178.
- [11] L. Kratz and K. Nishino, “Anomaly detection in extremely crowded scenes using spatio-temporal motion pattern models,” in *CVPR, 2009. CVPR 2009. IEEE Conference on*. IEEE, 2009, pp. 1446–1453.
- [12] T. Kimura, M. Ohashi, R. Okada, and H. Ikeno, “A new approach for the simultaneous tracking of multiple honeybees for analysis of hive behavior,” *Apidologie*, vol. 42, no. 5, pp. 607–617, 2011.
- [13] Y. W. Teh, M. I. Jordan, M. J. Beal, and D. M. Blei, “Hierarchical Dirichlet processes,” *Journal of the american statistical asso.*, vol. 101, no. 476, 2006.
- [14] X. Wang, W. E. L. Grimson, and C.-F. Westin, “Tractography segmentation using a hierarchical Dirichlet processes mixture model,” *NeuroImage*, vol. 54, no. 1, pp. 290–302, 2011.
- [15] F. I. Bashir, A. A. Khokhar, and D. Schonfeld, “View-invariant motion trajectory-based activity classification and recognition,” *Multimedia Systems*, vol. 12, no. 1, pp. 45–54, 2006.
- [16] N. Lemmens, S. De Jong, K. Tuyls, and A. Nowé, “Bee behaviour in multi-agent systems,” in *Adaptive Agents and Multi-Agent Systems III. Adaptation and Multi-Agent Learning*. Springer, 2008, pp. 145–156.