



Université
Paris Cité

école
normale
supérieure
paris-saclay

université
PARIS-SACLAY

Recherche de séquences typiques dans des séries temporelles symboliques. Application à la neuroscience comportementale.

Superviseurs.

- Charles Truong (CNRS, Université de Paris, ENS Paris-Saclay, SSA, INSERM) ctruong@ens-paris-saclay.fr
- Lucile Ben Haim, CNRS, Laboratoire des maladies neurodégénératives (CEA, CNRS, Université Paris-Saclay), Fontenay-aux-Roses

Mots-clés. Temporal Pattern Mining, Event Time Series, Behavioural Neuroscience, Computer Vision, Deep Learning

Présentation du laboratoire. Ce stage se déroulera au Centre Borelli (CNRS, Université de Paris, ENS Paris-Saclay, SSA, INSERM). Le Centre Borelli est une unité de recherche pluridisciplinaire axée sur toutes les applications des mathématiques, des neurosciences et de la recherche biomédicale. Il rassemble des équipes pluridisciplinaires de mathématiciens et d'experts en physique, mécanique, biologie et ingénierie pour mener des actions de recherche motivées par des données et des cas d'utilisation du monde réel.

Environnement. Le stagiaire aura l'occasion de s'intégrer pleinement dans une équipe interdisciplinaire composée de neurologues, de statisticiens et d'informaticiens. En cas de succès, le stage pourra faire l'objet de publications scientifiques. Le stage se déroulera à l'ENS Paris-Saclay (4 Avenue des Sciences, 91190 Gif-sur-Yvette). Le stagiaire assistera également à des séminaires de laboratoire hebdomadaires.

Contexte général. Pour mieux comprendre l'influence de l'état neurologique sur le comportement, il est nécessaire de quantifier ce comportement. Pour cela, une approche typique est de filmer des animaux cobayes pendant plusieurs minutes dans une cage et ensuite d'en extraire des descripteurs pertinents. Depuis quelques années, des outils de *deep learning* et *computer vision* sont disponibles pour extraire de ces vidéos les positions de l'animal (debout, à quatre pattes, etc.) [4] ou d'activités (toilette, interactions entre animaux) [5]. La problématique est alors de comparer les séquences de poses/activités. À part des approches simples (comptage, calcul de durées moyennes), très peu de méthodes sont disponibles pour quantifier et comparer le comportement.

Méthodologie proposée. Les données produites par les algorithmes de traitement vidéo sont considérées comme des séries d'événements (début et fin de poses). Elles ont une structure particulière, notamment non-vectorielle. L'absence de distance évidente ne permet pas d'appliquer les méthodes statistiques classiques.



Par ailleurs, il y a plusieurs échelles temporelles — certaines activités sont courtes et fréquentes, d'autres sont plus longues. Certaines activités peuvent également se superposer. Notre objectif est d'étendre à ce type de données des méthodes classiques, en particulier, le *clustering*, l'extraction de descripteurs complexes et pertinents, la détection de motifs (séquences typiques) et d'anomalies (séquences rares), et la comparaison de groupes (tests statistiques). De plus, pour utiliser ces nouveaux outils dans un contexte de recherche en neuroscience, il est nécessaire qu'ils soient interprétables. Ces contraintes sont communes à de nombreux contextes, qu'ils soient industriels ou financiers.

Stage. La première étape du stage est la prise en main des méthodes de traitement de vidéo (*computer vision*) basées sur des réseaux de neurones pour passer des vidéos à des séquences d'activités [4, 5]. Ensuite, le stagiaire se concentrera sur la tâche d'extraction de motifs et d'anomalies, en commençant par les méthodes proposées dans [1, 2, 3] voire [6]. Certaines utilisent des modèles de Markov à états cachés, d'autres préfèrent une représentation hiérarchique et une mesure de corrélation adaptée. Pour faire face au nombre immense de séquences possibles, il est attendu que l'algorithme développé soit computationnellement efficace, et capable de sélectionner les patterns pertinents. Ce travail pourra être valorisé par une publication en *machine learning*, traitement du signal ou *data mining*.

Références

- [1] Tavenard, R., Salah, A. A., & Pauwels, E. J. (2007). Searching for Temporal Patterns in Aml Sensor Data. *Constructing Ambient Intelligence (AMI)*, 53–62.
- [2] Batal, I., Valizadegan, H., Cooper, G. F., & Hauskrecht, M. (2013). A Temporal Pattern Mining Approach for Classifying Electronic Health Record Data. *ACM Transactions on Intelligent Systems and Technology*, 4(4). <https://doi.org/10.1145/2508037.2508044.A>
- [3] Avci, U., & Passerini, A. (2014). Improving activity recognition by segmental pattern mining. *IEEE Transactions on Knowledge and Data Engineering (TKDE)*, 26(4), 889–902. <https://doi.org/10.1109/TKDE.2013.127>
- [4] Mathis, A., Mamidanna, P., Cury, K. M., Abe, T., Murthy, V. N., Mathis, M. W., & Bethge, M. (2018). DeepLabCut: markerless pose estimation of user-defined body parts with deep learning. *Nature Neuroscience*, 21(9), 1281–1289. <https://doi.org/10.1038/s41593-018-0209-y>
- [5] Wiltschko, A. B., Tsukahara, T., Zeine, A., Anyoha, R., Gillis, W. F., Markowitz, J. E., Peterson, R. E., Katon, J., Johnson, M. J., & Datta, S. R. (2020). Revealing the structure of pharmacobehavioral space through motion sequencing. *Nature Neuroscience*, 23(11).
- [6] Wang, S., Cao, J., & Yu, P. S. (2022). Deep Learning for Spatio-Temporal Data Mining: A Survey. *IEEE Transactions on Knowledge and Data Engineering (TKDE)*, 34(8), 3681–3700. <https://doi.org/10.1109/TKDE.2020.3025580>