

Vers des Modèles Graphiques d'Événements soutenables et explicables pour apprendre et raisonner à partir de séquences d'événements

Encadrants : Philippe Leray (40%), Julien Blanchard (60%) – LS2N & Nantes Université

Résumé

Les modèles graphiques d'événements sont des modèles graphiques probabilistes proposés par [M14] pour décrire explicitement les dépendances temporelles entre événements. Nous proposons dans cette thèse de poursuivre les travaux existants autour de ces modèles dans deux directions: (1) l'inférence probabiliste, i.e. la possibilité d'interroger ces modèles à partir d'informations incertaines ou incomplètes, en nous intéressant aux aspects soutenabilité et explicabilité, et (2) l'apprentissage de ces modèles à partir de données en nous concentrant sur leur soutenabilité.

Mots-clés : Intelligence artificielle explicable, Intelligence artificielle soutenable, Apprentissage basé sur des modèles, Modèles graphiques d'événements, Inférence probabiliste

Descriptif du sujet de thèse

Avec la transformation numérique de nos sociétés, de nombreux domaines ont recours à la modélisation et l'analyse de séquences temporelles d'événements, comme en marketing (analyse comportementale des utilisateurs en ligne), en santé (monitoring patient, pharmacovigilance) ou dans la finance (détection de fraudes). Saisir la dynamique de ces flux de données nécessite de découvrir les structures cachées qui les régissent. C'est l'objet de différentes techniques d'IA, par exemple les réseaux de neurones récurrents et les modèles transformers pour lesquels l'intérêt s'est accru rapidement ces dernières années. Mais les modèles d'apprentissage profond ont une empreinte environnementale conséquente de par la puissance de calcul qu'ils requièrent pour leur entraînement. Du fait de leur nombre gigantesque de paramètres, ils ont aussi l'inconvénient de ne pas être directement interprétables. Cette thèse, au contraire, s'inscrit dans l'effort de recherche pour une **IA soutenable et interprétable** puisque nous proposons d'utiliser des **modèles graphiques d'événements** (Graphical Event Models ou GEM) pour modéliser les séquences d'événements.

De manière générale, les modèles graphiques probabilistes [KF09] sont des outils de représentation de connaissances en présence d'incertitude. Introduits par Meek dans [M14], les modèles graphiques d'événements sont capables de décrire explicitement les dépendances temporelles entre événements, tant dans leurs relations structurelles que dans leurs propriétés dynamiques. Dans [GM16], Gunawardana et Meek définissent une classe particulière de GEM, nommée Recursive Timescale GEM (RTGEM), qui peut approximer tout processus ponctuel temporel multivarié satisfaisant des contraintes de régularité faibles. Surtout, ils proposent un algorithme pour l'apprentissage de ces modèles à partir de données de séquences d'événements. Les RTGEM ont déjà fait l'objet de travaux dans l'équipe DUKE : application dans le domaine de la

sécurité [ADL19], apprentissage multi-tâches [ML19]. Ils sont actuellement mis en œuvre dans le cadre du projet CominLabs SPARS pour l'assistance à la modélisation de processus chirurgicaux.

Nous proposons de poursuivre ces travaux dans deux directions indépendantes : (1) l'inférence probabiliste, i.e. l'interrogation du modèle pour estimer la probabilité de variables non observées sachant celles observées, et (2) l'apprentissage à partir de données.

1. Inférence probabiliste soutenable et explicable

Les articles comme [GMX11] traitant de modèles précurseurs des RTGEM proposent d'utiliser un algorithme d'inférence approchée à base d'échantillonnage, en reprenant l'algorithme d'échantillonnage de [RGH05] ou un algorithme plus intéressant d'Importance Sampling adapté aux distributions de Poisson. Ces algorithmes n'ont pas encore été adaptés pour les modèles plus récents comme les RTGEM.

Une fois la réponse à la question posée au modèle obtenue par inférence probabiliste, il est possible de construire, comme pour tout modèle utilisé en IA, qu'il soit « boîte noire » ou pas, des indicateurs pour expliquer cette réponse. Les valeurs de Shapley sont des indicateurs de ce type [M23] qui ont été adaptés à des modèles graphiques probabilistes simples comme les réseaux bayésiens [HSB20], mais pas à des modèles plus complexes comme les RTGEM.

Dans cette thèse, nous nous proposons donc :

- de décrire de manière rigoureuse les types de questions l'on peut poser à un modèle graphique d'événements de type RTGEM, en nous inspirant par exemple de formalismes logiques [UM18] ;
- d'étudier l'adaptation des méthodes de type Importance Sampling pour répondre à ces types de questions de manière **soutenable** ;
- d'étudier l'adaptation de mesures comme les Shapley values pour que les sorties du modèle soient **explicables**.

2. Apprentissage soutenable

L'apprentissage de la structure et des paramètres d'un RTGEM nécessite de dénombrer les occurrences de suites d'événements dans les données. Il s'agit de déterminer par exemple combien de fois les événements A et B sont apparus ensemble dans les intervalles de 30 secondes qui précèdent un événement C. Comme de nombreuses combinaisons d'événements doivent être envisagées, l'apprentissage de la structure d'un RTGEM s'apparente pour partie à une tâche d'extraction d'épisodes, une classe particulière de motifs fréquents découvrables dans des séquences (voir [ONF23] pour un état de l'art). Nous proposons de tirer profit des algorithmes de ce domaine pour limiter la complexité de la procédure d'apprentissage de structure et la rendre plus soutenable. Parmi les approches récentes, on peut citer l'algorithme NONEPI qui extrait des occurrences d'épisodes disjointes [ONF21], et l'algorithme ONCE+ qui s'appuie sur une structure de données *ad hoc* pour accélérer la détection des occurrences [LPL19]. Les méthodes d'extraction de chroniques pourraient aussi s'avérer utiles pour notre problème [GBS20].

Dans cette thèse, nous nous proposons donc :

- de voir comment tirer au mieux parti des approches utilisées en fouille de données pour obtenir des algorithmes d'apprentissage de RTGEM qui soient plus **soutenables** que l'algorithme existant.

Les méthodes et algorithmes proposés durant la thèse seront implémentés dans la librairie C++ PILGRIM Evential. Cette librairie, dédiée aux modèles graphiques d'événements, fait partie de la

librairie PILGRIM dédiée plus généralement aux modèles graphiques probabilistes (réseaux bayésiens, réseaux bayésiens dynamiques, modèles relationnels probabilistes). Les algorithmes implémentés seront validés expérimentalement avec différents benchmarks générés aléatoirement, ou issus de la littérature, et de datasets classiquement utilisés en Process Mining.

Plan de travail

Les 18 premiers mois de la thèse seront dédiés à la compréhension des RTGEM et aux travaux concernant la partie Inférence Probabiliste. Les 12 mois suivants se concentreront sur la partie Apprentissage. Les 6 derniers mois seront consacrés à la finalisation des dernières expériences et à la rédaction du manuscrit de thèse.

Environnement de travail

Le doctorant travaillera au Laboratoire des Sciences du Numérique de Nantes (LS2N - UMR 6004), équipe DUKe, sur le campus de Polytech Nantes (site de La Chantrerie).

Profil du candidat

Le candidat doit être titulaire d'un master ou d'un diplôme équivalent en informatique. Le sujet est à l'intersection de la Statistique et du Machine Learning. Le candidat doit donc avoir une solide expérience dans au moins l'un de ces domaines.

Autres compétences requises :

- bonnes capacités en conception d'algorithmes et en programmation C++
- très bon niveau (écrit et oral) en anglais
- capacité de synthèse et aptitudes à la communication (orale et écrite)
- capacité à travailler en équipe
- autonomie, rigueur et motivation pour la recherche.

Instructions pour la candidature

Le dossier de candidature doit contenir les documents suivants :

1. un curriculum vitæ (CV) ;
2. les relevés de notes officiels des dernières formations d'enseignement supérieur du candidat (master, cycle ingénieur, etc.). Si le candidat termine actuellement un master, il doit envoyer le relevé des notes obtenues jusqu'à présent, avec le rang parmi ses pairs, et la liste des cours suivis au cours de la dernière année ;
3. quelques lettres de recommandation (la qualité est plus importante que la quantité) ;
4. une lettre de motivation rédigée spécifiquement pour ce poste.

Envoyez tous les documents par courrier électronique aux deux encadrants :

philippe.leray@ls2n.fr, julien.blanchard@ls2n.fr

La thèse de doctorat devrait débuter en septembre/octobre 2024.

Références bibliographiques

- [ADL19] Antakly, D., Delahaye, B., and Leray, P. (2019). Graphical event model learning and verification for security assessment. In 32th International Conference on Industrial Engineering and Other Applications of Applied Intelligent Systems, IEA/AIE 2019, July 9-11, 2019, Graz, Austria, pages 245-252. Springer International Publishing.
- [GBS20] Guyet, T., Besnard, P., Samet, A., Ben Salha, N. and Lachiche, N. (2020) Énumération des occurrences d'une chronique, in. EGC 2020 - 20ème édition de la Conférence Extraction et Gestion des Connaissances, pages 253-260.
- [GM16] Gunawardana, A. and Meek, C. (2016) Universal models of multivariate temporal point processes. In Proc. of AISTATS, pages 556–563.
- [GMX11] Gunawardana, A., Meek, C. and Xu, P. (2011) A model for temporal dependencies in event streams. In NIPS'11: Proceedings of the 24th International Conference on Neural Information Processing Systems, pages 1962–1970.
- [HSB20] Heskes, T., Sijben, E., Bucur, I., and Claassen, T. (2020). Causal Shapley Values: Exploiting Causal Knowledge. 34th Conference on Neural Information Processing Systems. Vancouver, Canada.
- [KF09] Koller, D. and Friedman, N. (2009) Probabilistic Graphical Models: Principle and Techniques. MIT Press, Cambridge.
- [LPL19] Li, H., Peng, S., Li, J., Li, J., Cui, J. and Ma, J. (2019) Counting the frequency of time-constrained serial episodes in a streaming sequence, Information Sciences, 505, pages 422–439.
- [M14] Meek, C. (2014) Toward learning graphical and causal process models. In Proc. of UAI workshop on Causal Inference: Learning and Prediction, pages 43–48.
- [M23] Molnar, C. (2022) Interpretable Machine Learning - A Guide for Making Black Box Models Explainable. christophm.github.io/interpretable-ml-book/
- [ML19] Monvoisin, M. and Leray, P. (2019). Multi-task transfer learning for timescale graphical event models. In Proceedings of the 15th European Conference on Symbolic and Quantitative Approaches to Reasoning with Uncertainty (ECSQARU 2019), pages 313-323, Belgrade, Serbia.
- [ONF21] Ouarem, O., Nouioua, F. and Fournier-Viger, P. (2021) Mining Episode Rules from Event Sequences Under Non-overlapping Frequency, in H. Fujita et al. (eds) Advances and Trends in Artificial Intelligence. Artificial Intelligence Practices. Cham: Springer International Publishing (Lecture Notes in Computer Science), pages 73–85.
- [ONF23] Oualid, O., Nouioua, F. and Fournier Viger, P. (2023) A survey of episode mining, Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery [Preprint].
- [RGH05] Rajaram, S., Graepel, T. and Herbrich, R. (2005) Poisson-networks: A model for structured point processes. In AISTats.
- [UM18] Ulus, D. and Maler, O. (2018) Specifying Timed Patterns using Temporal Logic, in Proceedings of the 21st International Conference on Hybrid Systems: Computation and Control (part of CPS Week). HSCC'18: 21st International Conference on Hybrid Systems: Computation and Control, Porto Portugal: ACM, pages 167–176.