

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
المدرسة العليا للإعلام الآلي 80 ماي 5491 بسيدي بلعباس
École Supérieure en Informatique
-08 Mai 1945- Sidi Bel Abbès



Final Year Thesis

To obtain the diploma of Engineer
Field: **Computer Science**
Speciality: **Artificial Intelligence and Data Science**

Theme

Change Point Detection in Temporal Graphs

Presented by:
SEHILI CHAIMA

Submitted on : **October, 2025**, In front of the jury composed of:

Dr. MAHAMMED Nadir
Dr. Dr. BELMEKKI Ghizelane Amira
Dr. Belkacem KHALDI
Dr. Esteban BAUTISTA Ruiz
Dr. Matthieu PUIGT
Dr. Laurent BRISSON

President
Examiner
Supervisor
Supervisor
Co-Supervisor
Co-Supervisor

ABSTRACT

Change point detection (CPD) in temporal graphs is a crucial task for identifying structural regime shifts in dynamic networks. However, existing approaches often struggle when communication data are sparse and volatile, as they rely on structural features or global statistics that are not adapted to such settings. They also lack the flexibility to evaluate changes across arbitrary substructures, which limits their applicability.

In this thesis, we adapt the Multi-Scale Anomaly Detection (MAD) framework to the problem of CPD in temporal graphs. MAD introduces a probabilistic and multi-scale analysis of subgraphs, producing a scoring function that identifies abrupt structural changes even in highly sparse data. The method is flexible, as it can detect change points at the edge, node, or graph level, and efficient, with linear complexity in both the length of the data and the number of analyzed communications.

Extensive experiments on synthetic and real-world datasets demonstrate that MAD produces sharp and consistent change point signals. It successfully recovers regime shifts across networks of varying densities and reveals meaningful structural transitions in real communication and organizational data. These results highlight MAD as a robust and scalable framework for CPD in temporal graphs, particularly effective in sparse and uncertain environments.

Keywords: Temporal Graphs, Change Point Detection, Unsupervised Learning, Multi-Scale Anomaly Detection

RÉSUMÉ

La détection de points de changement (CPD) dans les graphes temporels constitue une tâche essentielle pour identifier les transitions de régime structurel dans les réseaux dynamiques. Cependant, les approches existantes rencontrent souvent des difficultés lorsque les données de communication sont parcimonieuses et volatiles, car elles reposent sur des caractéristiques structurelles ou des statistiques globales qui ne sont pas adaptées à de tels contextes. Elles manquent également de flexibilité pour évaluer les changements à travers des sous-structures arbitraires, ce qui limite leur applicabilité.

Dans ce mémoire, nous adaptons l'algorithme Multi-Scale Anomaly Detection (MAD) au problème de la CPD dans les graphes temporels. MAD introduit une analyse probabiliste et multi-échelle des sous-graphes, produisant une fonction de score capable d'identifier des changements structurels brusques même dans des données hautement clairsemées. La méthode est flexible, car elle peut détecter des points de changement au niveau des arêtes, des nœuds ou du graphe global, et efficace, avec une complexité linéaire à la fois dans la longueur des données et dans le nombre de communications analysées.

Des expériences approfondies sur des jeux de données synthétiques et réels démontrent que MAD produit des signaux de points de changement nets et cohérents. Il parvient à détecter avec succès les transitions de régime dans des réseaux de densités variées et met en évidence des transitions structurelles significatives dans des données réelles de communication et d'organisation. Ces résultats confirment que MAD constitue un cadre robuste et évolutif pour la CPD dans les graphes temporels, particulièrement efficace dans des environnements clairsemés et incertains.

Mots-clés : Graphes temporels, Détection de points de changement, Apprentissage non supervisé, Multi-Scale Anomaly Detection

الملخص

تعدّ مهمة كشف نقاط التغيير في الرسوم البيانية الزمنية أساسية لتحديد التحولات الهيكلية في الشبكات الديناميكية. غير أنّ الطرق الحالية غالباً ما تواجه صعوبات عندما تكون بيانات الاتصال متفرقة ومتقلبة، لأنها تعتمد على خصائص هيكلية أو إحصاءات شاملة لا تتلاءم مع مثل هذه السياقات. كما تفتقر إلى المرونة في تقييم التغيرات عبر البنى الفرعية المختلفة، مما يحد من قابليتها للتطبيق.

في هذا العمل، قمنا بملاءمة إطار الكشف عن الشذوذ متعدد المقاييس لمشكلة كشف نقاط التغيير في الرسوم البيانية الزمنية. يقدم هذا الإطار تحليلاً احتمالياً ومتعدد المستويات للبنى الفرعية، مما ينتج دالة قياس قادرة على تحديد التغيرات الهيكلية المفاجئة حتى في البيانات شديدة التشتت. تتميز الطريقة بأنها مرنة، إذ يمكنها كشف نقاط التغيير على مستوى الحواف أو العقد أو الرسم البياني ككل، وفعّالة بفضل تعقيدها الخطي بالنسبة لطول البيانات وعدد الاتصالات المحلّلة.

أظهرت التجارب على بيانات تركيبية وحقيقية أنّ هذا الإطار يُنتج إشارات دقيقة ومتسقة لنقاط التغيير. كما ينجح في استرجاع التحولات في الشبكات ذات الكثافات المختلفة، ويكشف عن انتقالات هيكلية ذات معنى في بيانات واقعية خاصة بالاتصالات والتنظيم. تؤكد هذه النتائج أنّ الكشف عن الشذوذ متعدد المقاييس يُمثل إطاراً قوياً وقابلاً للتوسع لكشف نقاط التغيير في الرسوم البيانية الزمنية، وفعّالاً بشكل خاص في البيئات المتفرقة وغير المؤكدة.

الكلمات المفتاحية: الرسوم البيانية الزمنية، كشف نقاط التغيير، التعلم غير المراقب، الكشف عن الشذوذ متعدد المقاييس