

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



## THESIS

To obtain the diploma of **Engineer**  
Field: **Computer Science**  
Specialty: **Artificial Intelligence & Data science(IASD)**

### Theme

---

## Towards Transparent Recommender System

---

Presented by:  
**ZAGHLAOUI Karim**

Submission Date: **Sept, 2024**  
In front of the jury composed of:

**Mr. KHALDI Belkacem**  
**Ms. DIF Nassima**  
**Ms. BOUZEGHOUB Amel**  
**Ms. BENCHERIF Khayra**

President  
Supervisor  
Co-Supervisor  
Examiner

*Academic Year : 2023/2024*

# Abstract

Following significant advancements in graph neural networks (GNNs) for representation learning on static graphs, the development of temporal graph neural networks (TGNNS) has emerged as a powerful approach. TGNNS excel in modeling the dynamic nature of temporal graphs, achieving state-of-the-art performance across various predictive tasks. Their success has extended to critical applications such as financial forecasting, fraud detection, and recommendation systems, where the ability to explain model predictions is essential. However, the integration of both temporal and spatial dimensions in TGNNS has resulted in complex models that are difficult to interpret. While many established techniques exist for explaining predictions in static graph models, these methods do not easily generalize to temporal settings. Recently, a few methods have been introduced to explain TGNN predictions, primarily focusing on discrete time series, with the continuous-time setting remaining largely unexplored.

In this work, we explore the key aspects of recommendation systems and the explainability of graph neural networks. Additionally, we introduce our approach, accompanied by a comparative study with state-of-the-art methods, and discuss the practical tools employed for development and deployment.

**Keywords**— Explainable artificial Intelligence (XAI), Temporal Graph Neural Networks (TGNNS), Link Prediction, Recommendation System

# الملخص

بعد التقدم الكبير الذي حققته شبكات التعلم العميق على الرسوم البيانية الثابتة، ظهرت شبكات التعلم العميق على الرسوم البيانية الزمنية (TGNNs) كنهاج قوي. تميزت هذه الشبكات بقدرتها على نمذجة الطبيعة الديناميكية للرسوم البيانية الزمنية، مما جعلها تحقق أداءً رائداً في مجموعة واسعة من المهام التنبؤية. امتدت نجاحات هذه النماذج إلى تطبيقات حاسمة مثل التنبؤات المالية، واكتشاف الاحتيال، وأنظمة التوصيات، حيث يعتبر تفسير توقعات النموذج أمراً بالغ الأهمية. ومع ذلك، فإن دمج الأبعاد الزمنية والمكانية في نماذج الرسوم البيانية الزمنية أدى إلى تعقيد النماذج وجعل تفسيرها صعباً. ورغم وجود العديد من التقنيات الراسخة لتفسير توقعات النماذج الرسومية الثابتة، فإن هذه الأساليب لا تعمم بسهولة على الحالات الزمنية. مؤخراً، ظهرت بعض الأساليب لتفسير توقعات نماذج TGNNs لكنها ركزت بشكل أساسي على السلسل الزمنية المنفصلة، مما ترك الحالات الزمنية المستمرة دون استكشاف كاف.

في هذا العمل، نستعرض الجوانب الرئيسية لأنظمة التوصيات ومفهوم قابلية التفسير في شبكات التعلم العميق على الرسوم البيانية. بالإضافة إلى ذلك، نقدم نهجنا، مع دراسة مقارنة مع الأساليب الحديثة، وتناول الأدوات العملية المستخدمة في التطوير والنشر.

الكلمات المفتاحية --- الذكاء الاصطناعي التفسيري (XAI)، شبكات التعلم البياني الزمني (TGNNs)، التنبؤ بالروابط،  
نظم التوصية

# Résumé

Après les avancées majeures des réseaux de neurones sur graphes (GNNs) dans l'apprentissage de représentation sur des graphes statiques, le développement des réseaux de neurones sur graphes temporels (TGNNs) est apparu comme une approche puissante. Les TGNNs excelltent dans la modélisation de la nature dynamique des graphes temporels, atteignant des performances de pointe dans diverses tâches prédictives. Leur succès s'est étendu à des applications critiques telles que la prévision financière, la détection de fraude et les systèmes de recommandation, où la capacité à expliquer les prédictions du modèle est essentielle. Cependant, l'intégration des dimensions temporelles et spatiales dans les TGNNs a conduit à des modèles complexes, difficiles à interpréter. Bien que de nombreuses techniques bien établies existent pour expliquer les prédictions des modèles de graphes statiques, ces méthodes ne se généralisent pas facilement aux contextes temporels. Récemment, quelques méthodes ont été introduites pour expliquer les prédictions des TGNNs, en se concentrant principalement sur les séries temporelles discrètes, laissant les cas en temps continu largement inexplorés.

Dans ce travail, nous explorons les aspects clés des systèmes de recommandation et l'explicabilité des réseaux de neurones sur graphes. De plus, nous présentons notre approche, accompagnée d'une étude comparative avec les méthodes de pointe, et discutons des outils pratiques utilisés pour le développement et le déploiement.

**Mots-clés**— Intelligence Artificielle Explicable (XAI), Réseaux Neuronaux Graphiques Temporels (TGNN), Prédiction de Lien, Système de Recommandation