

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 **Master**
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

After the major breakthroughs advancements of graph neural networks in representation learning on static graphs, strong models called temporal graph neural networks (TGNNS) have been developed. The ability to effectively model the dynamic nature of a temporal graph made TGNNS achieve state-of-the-art performance across a wide range of predictive tasks. The success of these models has led to their application in critical tasks such as financial forecasting, fraud detection, and recommendation systems, where the ability to explain the model’s predictions is crucial. However, incorporating both temporal and spatial aspects in temporal graph models has turned them into complex models that are challenging to explain. While numerous well-established techniques exist to explain the predictions of static graph models, they are not easily generalized to the temporal cases. Recently, few methods have emerged to explain the predictions made by TGNNS focusing on discrete time series on the graph, leaving the continuous-time setting underexplored.

In this master, we introduced the main aspects of recommendation systems, and the graph neural networks approach. Then we introduced the notions of explainable artificial intelligence and presented the state of the art of explainability methods employed to explain temporal graph neural networks.

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

الملخص

بعد الإنجازات الكبيرة في شبكات التعلم التمثيلي للشبكات البيانية الثابتة، تم تطوير نماذج قوية تسمى شبكات التعلم البياني الزمني . (TGNNs) قدرة هذه النماذج على تمثيل الطبيعة الديناميكية للشبكة الزمنية جعلتها تحقق أداءً متقدماً في مجموعة واسعة من المهام التنبؤية. أدى نجاح هذه النماذج إلى استخدامها في مهام حاسمة مثل التنبؤ المالي، واكتشاف الاحتيال، وأنظمة التوصية، حيث تكون القدرة على تفسير تنبؤات التموج أمرًا بالغ الأهمية. ومع ذلك، فإن دمج الجوانب الزمنية والمكانية في نماذج الشبكات الزمنية جعلها نماذج معقدة يصعب تفسيرها. في حين أن هناك العديد من التقنيات الراسخة لتفسير تنبؤات نماذج الشبكات الثابتة، إلا أنه لا يمكن تعميمها بسهولة على الحالات الزمنية. مؤخرًا، ظهرت بعض الأساليب لتفسير التنبؤات التي تقوم بها TGNNs وتركز على السلسلة الزمنية المتقطعة على الشبكة، مما يجعل الإعداد الزمني المستمر غير مستكشف بشكل كاف.

في هذه الأطروحة، قدمنا الجوانب الرئيسية لأنظمة التوصية، ونرج شبكات التعلم البياني. ثم قدمنا مفاهيم الذكاء الاصطناعي التفسيري واستعرضنا أحد الأساليب المستخدمة لتفسير شبكات التعلم البياني الزمني.

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

Résumé

Après les avancées majeures des réseaux neuronaux graphiques dans l'apprentissage de la représentation sur des graphes statiques, des modèles puissants appelés réseaux neuronaux graphiques temporels (TGNN) ont été développés. La capacité de modéliser efficacement la nature dynamique d'un graphe temporel a permis aux TGNN d'atteindre des performances de pointe dans un large éventail de tâches prédictives. Le succès de ces modèles a conduit à leur application dans des tâches critiques telles que la prévision financière, la détection de fraude et les systèmes de recommandation, où la capacité d'expliquer les prédictions du modèle est cruciale. Cependant, l'intégration des aspects temporels et spatiaux dans les modèles graphiques temporels les a rendus complexes et difficiles à expliquer. Alors que de nombreuses techniques bien établies existent pour expliquer les prédictions des modèles graphiques statiques, elles ne sont pas facilement généralisables aux cas temporels. Récemment, quelques méthodes ont émergé pour expliquer les prédictions faites par les TGNN en se concentrant sur les séries temporelles discrètes sur le graphe, laissant le cadre du temps continu inexploré.

Dans ce mémoire, nous avons introduit les principaux aspects des systèmes de recommandation et l'approche des réseaux neuronaux graphiques. Ensuite, nous avons introduit les notions d'intelligence artificielle explicable et présenté l'état de l'art des méthodes de explicabilité utilisées pour expliquer les réseaux neuronaux graphiques temporels.

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