

Adaptive GNN Maintenance using Reinforcement Learning for Robust Financial Fraud Detection

Por Renner S. Menezes e Raimir Holanda Filho

Fonte: OpenAlex · Unifor · [Publicação original](#)

INOVAÇÃO

9/10

APLICABILIDADE

9/10

POTENCIAL
ECONÔMICO

9/10

MATURIDADE

Média

Este paper apresenta um framework inovador que utiliza Reinforcement Learning (RL) para a manutenção adaptativa de Graph Neural Networks (GNNs), visando robustez na detecção de fraudes financeiras. A solução aborda o problema crítico de 'concept drift' em ambientes de produção, onde a performance de GNNs é comprometida. O agente de RL aprende a intervir de forma inteligente, resultando em uma melhoria significativa no F1-score (0.9222 médio) em comparação com modelos estáticos e estratégias de retreinamento periódicas, oferecendo uma solução promissora para a estabilidade e eficácia de sistemas de detecção de fraude.

NÚCLEO DA ANÁLISE

Ideia de startup ou produto

Uma startup poderia desenvolver uma plataforma SaaS chamada 'Adaptive FraudShield AI', que oferece um motor de detecção de fraudes baseado em GNNs e otimizado por RL. O diferencial seria a capacidade de auto-adaptação contínua a novos padrões de fraude, minimizando a necessidade de intervenção manual e garantindo alta performance em tempo real, com foco em bancos digitais e fintechs que necessitam de agilidade.

Aplicações práticas

A aplicação prática mais evidente é em instituições financeiras (bancos, operadoras de cartão de crédito, fintechs) para detecção de fraudes em tempo real e anti-lavagem de dinheiro (AML). Também pode ser adaptado para detecção de anomalias em cibersegurança, detecção de fraude em seguros e qualquer domínio onde GNNs são empregadas e o 'concept drift' representa um desafio significativo para a manutenção do desempenho.

Potencial de mercado

O mercado global de detecção e prevenção de fraudes financeiras é vasto e está em constante crescimento, impulsionado pela digitalização e pela sofisticação das ameaças. Soluções que oferecem maior precisão, adaptabilidade e automação, como a proposta neste paper, têm um potencial de mercado altíssimo, pois resolvem

um ponto de dor crítico para a resiliência e lucratividade das instituições financeiras, reduzindo perdas e custos operacionais.

FUNDAMENTO CIENTÍFICO

Problema abordado

O principal problema abordado é a instabilidade de desempenho de Graph Neural Networks (GNNs) em produção para detecção de fraudes financeiras, causada pelo 'concept drift'. Este fenômeno, onde os padrões de fraude evoluem, degrada criticamente a eficácia dos modelos ao longo do tempo, exigindo intervenções de manutenção complexas e ineficientes.

Metodologia

A metodologia propõe um framework que integra um agente de Reinforcement Learning (RL) para gerenciar a manutenção adaptativa de uma Relational Graph Convolutional Network (R-GCN). A R-GCN opera sobre um grafo de conhecimento heterogêneo de transações financeiras. O agente de RL monitora continuamente o desempenho da GNN e aprende uma política sofisticada para decidir quando e como intervir (e.g., retreinar, ajustar parâmetros) para otimizar a performance em ambientes voláteis. A validação foi realizada com 5-fold temporal cross-validation.

Principais descobertas

Os principais achados demonstram que o agente de RL alcançou um F1-score médio de 0.9222, com picos de 0.9771, superando significativamente um modelo estático (0.8929), uma estratégia ingênua de retreinamento periódico (0.9074) e uma baseline competitiva de detecção de drift ADWIN (0.8993). Os resultados, validados por testes de Wilcoxon ($p < 0.05$), confirmam que o agente de RL pode aprender uma política de intervenção inteligente e eficiente para maximizar o desempenho em ambientes financeiros voláteis.

LEITURA PARA GESTÃO PÚBLICA

Este estudo pode informar políticas públicas em duas frentes: 1) **Regulamentação e Incentivo**: O Banco Central do Brasil e a CVM poderiam usar esses insights para criar diretrizes ou 'sandboxes' regulatórios que incentivem a adoção de IA adaptativa para segurança financeira, promovendo inovação responsável. 2) **Financiamento à Pesquisa**: Justificar investimentos públicos em P&D para tecnologias de IA que aumentem a resiliência do sistema financeiro nacional contra fraudes e ciberataques, fomentando a colaboração universidade-indústria.

PARCERIA UNIVERSIDADE × EMPRESA

Parcerias estratégicas poderiam ser estabelecidas com grandes bancos brasileiros (e.g., Itaú, Bradesco, Banco do Brasil) ou fintechs (e.g., Nubank, C6 Bank) para projetos piloto e co-desenvolvimento da tecnologia em escala real. Também há potencial de parceria com empresas de software financeiro (e.g., FICO, SAS) para integração da solução em suas plataformas existentes, ou com provedores de infraestrutura de nuvem (e.g., AWS, Google Cloud) para otimização de escalabilidade e deployment.

4 direções estratégicas identificadas

STARTUP · IMPACTO ALTO · INTELIGÊNCIA ARTIFICIAL

Adaptive FraudShield AI

Desenvolvimento de uma startup SaaS focada em oferecer um sistema de detecção de fraudes financeiras baseado em GNNs com manutenção adaptativa por Reinforcement Learning, garantindo alta performance e resiliência contra 'concept drift' para bancos e fintechs.

PRODUTO CORPORATIVO · IMPACTO ALTO · SOFTWARE

Módulo de Detecção de Fraude Adaptativa para Plataformas Financeiras

Integração da tecnologia de manutenção adaptativa de GNNs via RL como um módulo avançado em plataformas existentes de detecção de fraudes de grandes fornecedores de software financeiro, como FICO ou SAS, para aprimorar a capacidade de adaptação e precisão de seus produtos.

PARCERIA · IMPACTO ALTO · CIÊNCIA DE DADOS

UNIFOR & Banco: Projeto Piloto de Detecção de Fraude Adaptativa

Colaboração entre a UNIFOR e um grande banco brasileiro (e.g., Itaú, Bradesco) para um projeto piloto de pesquisa e desenvolvimento, aplicando e validando o framework de GNNs com RL em dados reais de transações financeiras, visando a implementação em larga escala.

POLÍTICA PÚBLICA · IMPACTO MÉDIO · GOVTECH

Sandbox Regulatório para IA em Segurança Financeira

Proposta ao Banco Central do Brasil para a criação de um 'sandbox' regulatório que permita a experimentação e validação de soluções inovadoras de IA, como a manutenção adaptativa de modelos, para fortalecer a segurança e a resiliência do sistema financeiro contra fraudes.

ABSTRACT ORIGINAL

Graph Neural Networks (GNNs) are highly effective for financial fraud detection, yet their performance in production is critically undermined by concept drift, which often manifests as severe performance instability. This paper proposes a novel framework for the adaptive maintenance of GNN driven by a Reinforcement Learning (RL) agent designed to navigate this volatility. Our solution features a Relational Graph Convolutional Network (R-GCN) that operates on a heterogeneous knowledge graph of financial transactions. An autonomous RL agent monitors the GNN's performance and learns a sophisticated policy to decide when and how to intervene. Through a rigorous 5-fold temporal cross-validation, we demonstrate that our RL agent achieves a mean F1-score of 0.9222, with peaks of 0.9771, significantly outperforming a static model (0.8929), a naive periodic retraining strategy (0.9074), and a competitive ADWIN drift detection baseline (0.8993). The results, validated by Wilcoxon signed rank tests ($p < 0.05$ against all baselines), demonstrate that an RL agent can learn an intelligent and efficient intervention policy that maximizes performance in volatile environments.

PALAVRAS-CHAVE

Reinforcement learning · Retraining · Graph · Rank (graph theory) · Baseline (sea) · Convolutional neural network · Wilcoxon signed-rank test