



融合图增强与多教师动态蒸馏的区块链异常交易检测方法

张铭泉, 贾文莉, 孟丽敏, 赵峻贤

引用本文:

张铭泉, 贾文莉, 孟丽敏, 等. 融合图增强与多教师动态蒸馏的区块链异常交易检测方法[J]. 智能系统学报, 2026, 21(5): 1154-1165.

ZHANG Mingquan, JIA Wenli, MENG Limin, et al. A blockchain abnormal transaction detection method integrating graph enhancement and multi-teacher dynamic distillation[J]. CAAI transactions on intelligent systems, 2026, 21(5): 1154-1165.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202510002>

您可能感兴趣的其他文章

非结构化文档敏感数据识别与异常行为分析

Unstructured document sensitive data identification and abnormal behavior analysis
智能系统学报. 2021, 16(5): 932-939 <https://dx.doi.org/10.11992/tis.202104028>

结合卷积特征提取和路径语义的知识推理

Knowledge-based inference on convolutional feature extraction and path semantics
智能系统学报. 2021, 16(4): 729-738 <https://dx.doi.org/10.11992/tis.202008007>

用于关系抽取的注意力图长短时记忆神经网络

Attention graph long short-term memory neural network for relation extraction
智能系统学报. 2021, 16(3): 518-527 <https://dx.doi.org/10.11992/tis.202008036>

基于图勾勒的图链路预测方法

Graph sketches-based link prediction over graph data
智能系统学报. 2019, 14(4): 761-768 <https://dx.doi.org/10.11992/tis.201806007>

图正则化字典对学习的轻度认知功能障碍预测

Dictionary pair learning with graph regularization for mild cognitive impairment prediction
智能系统学报. 2019, 14(2): 369-377 <https://dx.doi.org/10.11992/tis.201709033>

依特征频率的安卓恶意软件异常检测的研究

Android malware outlier detection based on feature frequency
智能系统学报. 2018, 13(2): 168-173 <https://dx.doi.org/10.11992/tis.201609016>

DOI: 10.11992/tis.202510002

网络出版地址: <https://link.cnki.net/urlid/23.1538.tp.20260317.1450.003>

融合图增强与多教师动态蒸馏的 区块链异常交易检测方法

张铭泉^{1,2}, 贾文莉¹, 孟丽敏³, 赵峻贤¹

(1. 华北电力大学 控制与计算机工程学院, 河北 保定 071003; 2. 华北电力大学 复杂能源系统智能计算教育部工程研究中心, 河北 保定 071003; 3. 华北电力大学 网络与信息化办公室, 河北 保定 071003)

摘要: 针对现有区块链异常交易检测方法在复杂交易结构建模与数据不平衡处理方面的不足, 本文提出一种融合图神经网络多教师模型、motif 结构特征、SMOTE(synthetic minority oversampling technique) 采样与双学生模型知识蒸馏的检测方法——MGDD (multi-teacher GNN dynamic distillation)。该方法首先利用 motif 统计量增强节点结构表达, 随后结合图卷积网络、图注意力网络、图同构网络、图采样与聚合网络构建多教师模型, 通过动态蒸馏机制引导多层感知机与随机森林学生模型学习图中的高阶语义特征, 并引入 SMOTE 进行过采样以缓解样本不平衡问题。在 Elliptic 数据集上的实验结果表明, MGDD 在准确率、召回率与 F1 值等指标上全面优于现有典型方法, 其中 RF 学生模型在蒸馏引导下准确率达到 99.23%。消融与鲁棒性实验进一步验证了 motif 特征与知识蒸馏机制在提升检测性能与模型稳定性方面的重要作用。综上所述, MGDD 为区块链异常交易检测任务提供了一种高效、可推广的建模范式, 具备良好的应用前景。

关键词: 区块链; 异常检测; 图神经网络; 知识蒸馏; SMOTE; 多教师模型; 动态蒸馏; 特征增强

中图分类号: TP309; TP18 **文献标志码:** A **文章编号:** 1673-4785(2026)05-1154-12

中文引用格式: 张铭泉, 贾文莉, 孟丽敏, 等. 融合图增强与多教师动态蒸馏的区块链异常交易检测方法 [J]. 智能系统学报, 2026, 21(5): 1154-1165.

英文引用格式: ZHANG Mingquan, JIA Wenli, MENG Limin, et al. A blockchain abnormal transaction detection method integrating graph enhancement and multi-teacher dynamic distillation[J]. CAAI transactions on intelligent systems, 2026, 21(5): 1154-1165.

A blockchain abnormal transaction detection method integrating graph enhancement and multi-teacher dynamic distillation

ZHANG Mingquan^{1,2}, JIA Wenli¹, MENG Limin³, ZHAO Junxian¹

(1. School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China; 2. Engineering Research Center of Intelligent Computing for Complex Energy Systems, Ministry of Education, North China Electric Power University, Baoding 071003, China; 3. Network and Information Office, North China Electric Power University, Baoding 071003, China)

Abstract: To address the limitations of existing blockchain abnormal transaction detection methods in complex transaction structure modeling and data imbalance handling, this paper proposes a detection method called MGDD (multi-teacher GNN dynamic distillation) that integrates graph neural network teacher models, motif structural features, SMOTE sampling, and multi-student model knowledge distillation. This method first enhances node structural representation using motif statistics, then constructs multiple teacher models by combining GCN, GAT, GIN, and GraphSAGE graph neural networks. Through a dynamic distillation mechanism, it guides multi-layer perceptron (MLP) and random forest (RF) student models to learn high-order semantic features from graphs, and introduces SMOTE for over-sampling to alleviate the sample imbalance problem. Experimental results on the Elliptic dataset demonstrate that MGDD outperforms existing typical methods in terms of accuracy, recall rate, and F1-score, with the RF student model achieving an accuracy rate of 99.23% under the guidance of distillation. Ablation and robustness experiments further verify the important role of motif features and knowledge distillation mechanisms in improving detection performance and model stability. In summary, MGDD provides an efficient and scalable modeling paradigm for blockchain abnormal transaction detection tasks, showing promising application prospects.

Keywords: blockchain; anomaly detection; graph neural network; knowledge distillation; SMOTE; multi-teacher model; dynamic distillation; feature enhancement

收稿日期: 2025-10-08. 网络出版日期: 2026-03-18.

基金项目: 国家自然科学基金青年基金项目 (61802124); 中央高校基本科研业务费专项项目 (2020MS122).

通信作者: 孟丽敏. E-mail: menglm@ncepu.edu.cn.

近年来, 随着区块链技术在金融、供应链、数字资产等领域的广泛应用, 其匿名性和去中心化特性在带来技术红利的同时, 也为非法交易、洗

钱等行为提供了新的可乘之机。异常交易行为的识别,尤其是在复杂的区块链交易图中发现隐蔽的异常账户,已成为当前金融安全与智能风控研究的热点问题之一。与传统金融交易数据不同,区块链交易数据天然具有图结构特性:每个地址和交易可以建模为图中的节点,资金的流动关系则表现为边。这种图结构特性促使研究者广泛采用图神经网络(graph neural networks, GNN)来建模和分析区块链交易行为,利用其在图结构学习上的优势,以识别潜在的异常交易。尽管现有研究中,GCN^[1](graph convolutional network)、GAT^[2](graph attention network)、GraphSAGE(graph sample and aggregate)等GNN模型^[3]已被应用于区块链异常交易检测任务,并取得了一定成效,但仍存在以下几方面的挑战:1)结构信息表达能力不足。传统GNN主要依赖一阶邻居信息聚合,难以捕捉复杂的交易行为模式和高阶结构特征,导致对隐蔽性强的异常交易检测性能不佳;2)训练成本高、推理效率低。主流GNN模型计算开销大,参数复杂度高,在处理大规模区块链交易数据时,训练时间过长,且难以在实时或边缘设备上快速部署,无法满足实际应用中实时性的要求。3)类别不平衡问题显著。在实际区块链数据中,异常交易通常占比极低,传统模型易受到多数类样本的影响,导致对少数类异常交易的检测性能下降,出现漏检等情况,严重影响检测效果。

为应对上述挑战,本文提出一种融合图结构增强与多教师知识蒸馏的区块链异常交易检测框架MGDD(multi-teacher guided distillation for detection)。本研究的创新贡献包括:1)构造了融合motif与时序特征的节点特征增强机制,利用motif结构挖掘交易图中的高阶局部结构模式,有效增强图表示的表达能力,从而解决了传统GNN结构信息表达能力不足的问题。2)设计了多教师图神经网络架构,集成GCN、GAT、GIN和GraphSAGE这4种异构GNN模型,从多视角联合学习图结构表示,为后续知识迁移提供丰富的知识基础。3)引入知识蒸馏机制,构建了随机森林RF(random forest)和动态蒸馏多层感知机(multi-layer perceptron, MLP)双学生模型蒸馏架构,将教师网络中学习到的知识迁移给轻量级学生模型,兼顾准确性与推理效率,解决了主流GNN模型训练成本高、推理效率低的问题。4)提出了结合DropEdge随机边裁剪和SMOTE(synthetic minority oversampling technique)过采样技术,分别增强模

型泛化能力和缓解类别不平衡问题。实验结果表明,MGDD框架在保持较高检测准确率的同时,显著提升了模型的效率与鲁棒性,为大规模区块链环境中的异常交易检测提供了一种有效途径。

1 相关工作

随着区块链技术在加密货币、智能合约与去中心化金融等领域的迅速普及,其匿名性与不可篡改性特征虽然提升了数据安全,但也被不法分子滥用,导致链上非法交易行为日益频繁。如何有效识别异常交易行为,已成为保障区块链系统安全与合规的重要研究方向。目前,区块链异常交易检测方法主要可分为:基于规则和特征工程的传统机器学习方法、基于图神经网络的方法及融合高阶结构的方法。

近年来,研究者进一步在图神经网络框架内引入高阶结构(motif)、知识蒸馏与样本平衡等轻量化增强策略,以应对类别不平衡和部署效率问题。

1.1 基于规则与特征工程的传统机器学习方法

早期研究主要依赖专家经验构建规则或提取统计特征,结合支持向量机(support vector machine, SVM)、决策树(decision tree)、逻辑回归(logistic regression)等传统分类器实现异常检测。传统的区块链异常交易检测方法多依赖规则匹配^[4]或基于统计学习的浅层特征提取^[5],难以刻画交易行为的复杂图结构与演化特性,检测效果有限。文献[6-7]将同一交易输入地址中的多个找零地址归并为一个实体,从而提升实体的聚合程度。然而,非法用户混淆实体模式,隐私保护技术增强匿名性,导致传统规则启发式实体识别性能不高。一些方法通过分析交易金额分布、频率、时间间隔等特征实现识别,如Farrugia等^[8]通过分析44个基于历史交易记录的特征,发现对检测以太坊非法账户影响最大的3个特征是交易时间差、可用余额和收到的最小以太币值。而Ibrahim等^[9]则是在上面的基础上,选取了6个最重要的交易特征。王栋等^[10]使用主成分分析对区块链数据进行线性和非线性降维;朱会娟等^[11]设计了残差网络结构,将高层抽象特征与浅层特征自适应的融合,并挖掘两者的交叉信息获得更具有区分力的特征。然而,在面对复杂隐蔽的交易行为时泛化能力有限,难以满足实际检测需求。同时,区块链中的交易和账户之间存在复杂的网络关系,传统方法难以有效捕捉这些关系,而异常交易检测需要分析这种复杂关系。

1.2 基于图神经网络的方法

由于区块链交易天然构成复杂的图结构, GNN 在区块链异常交易检测^[12]领域展现出了强大的潜力, 近年来成为主流的异常检测手段。GCN、GAT 和 GraphSAGE 等经典 GNN 模型已被应用于比特币、以太坊等链上交易图中, 通过节点聚合机制学习交易节点的图表示, 捕捉其上下文行为特征。例如, Elliptic 团队率先使用 GCN 进行加密货币交易分类任务^[4], 展示了 GNN 模型在捕捉图结构中的上下文行为特征方面的潜力。文献^[13]考虑了区块链交易网络的拓扑结构, 提取了交易图的领域和局部特征, 并将其应用于集成方法中。Nerurkar^[14]为识别比特币上的非法交易, 基于比特币网络提取的交易特征结合谱图卷积网络提出了一种深度学习图神经网络模型。然而, 现有 GNN 方法仍面临三方面挑战: 1) 多数模型仅聚合一阶邻居信息, 难以建模高阶交易模式; 2) GNN 结构复杂、参数量大, 导致训练开销高、部署难度大; 3) 区块链交易中异常样本占比较低, 导致类别不平衡问题严重影响模型性能。

1.3 图结构增强与模型轻量化方法

为增强图表示能力, 研究者引入图结构模式 (motif) 以挖掘交易网络中的高阶结构信息, 如三角形、星型等。Chen 等^[15]和 Jourdan 等^[16]将 motif 应用于构建离散时间交易图, 提取节点的交互频次与金额等行为特征, 有助于识别匿名账户、理解网络行为。同时, Rong 等^[17]的结构扰动方法被用于缓解过拟合, 提升模型的泛化与鲁棒性。

此外, 知识蒸馏 (knowledge distillation) 已被用于图神经网络中。然而, 现有图神经网络蒸馏研究多集中于单教师架构^[18], 而对多种 GNN 模型知识进行协同融合的研究仍较为有限。Yang 等^[19]通过将性能强但复杂的教师网络 (如 GNN) 学习的知识迁移至轻量化学生模型 (如多层感知机 MLP、随机森林 RF), 显著降低了模型计算成本, 同时保持了检测性能。Zhou 等^[20]提出了一种基于图神经网络的 holistic 知识蒸馏方法 HKD (holistic knowledge distillation), 通过整合个体知识和关系知识来指导学生网络的学习。针对类别不平衡问题, 合成少数类样本技术 (如 SMOTE) 也被引入到图节点分类与异常检测中, 缓解少数类样本不足带来的训练偏差, 如 Zhang 等^[21]提出了一种结合 ENN-SMOTE (edited nearest neighbors synthetic minority oversampling technique) 采样和注意力机制的图卷积网络模型, 用于解决图节点分类中的类别不平衡问题。ENN-SMOTE 通过增加少

数类节点并减少多数类节点来平衡数据集。

总之, 当前区块链异常交易检测方法在建模高阶结构特征、提升模型推理效率、缓解类别不平衡等方面仍存在瓶颈。为此, 本文提出一种融合高阶 motif 特征、图神经表示学习、多教师知识蒸馏与样本平衡策略 (SMOTE) 的轻量级检测框架 MGDD, 旨在保证检测性能的同时, 提升模型的可扩展性与部署效率。

2 方法设计

MGDD 是一种多教师图神经网络模型与动态知识蒸馏机制的区块链异常交易检测方法, 整体方法框架如图 1 所示, 旨在保持检测精度的同时降低模型推理成本, 以适应大规模交易图中对实时、轻量风控的实际需求。主要包含 4 个关键模块: 特征增强模块、多教师图神经网络模块、动态蒸馏与学生模型模块、鲁棒训练策略模块。




图 1 MGDD 框架

Fig. 1 Framework of MGDD

2.1 特征增强: motif 结构与时间行为融合

区块链交易图具备复杂的结构与行为模式, 原始数值特征 (如金额、时间戳) 难以充分刻画异常行为。为提升模型对可疑交易模式的感知能力, 本文引入结构与时间 2 个维度的增强特征。

2.1.1 Motif 特征提取

在结构维度上, 本文提取每个节点的高阶图结构指标, 包括三角形数量 (triangle count)、聚类

系数 (clustering coefficient) 与介数中心性 (betweenness centrality) 等。这些指标有助于揭示节点在图中的结构特征和行为模式。

三角形数量可揭示混币行为中常见的密集局部子图, 公式表示为

$$T_i = \frac{1}{2} \sum_{j \in N(i)} \sum_{k \in N(i) \cap N(j)} 1$$

式中: T_i 表示节点 i 的三角形数量, $N(i)$ 是节点 i 的邻居节点集合。聚类系数主要衡量节点邻居间的紧密程度, 异常账户往往形成高聚集度结构, 公式表示为

$$C_i = \frac{2T_i}{k_i(k_i - 1)}$$

式中: C_i 表示节点 i 的聚类系数, k_i 是节点 i 的度数。介数中心性可识别转账路径中的关键中介节点, 有助于捕捉洗钱网络中的枢纽角色, 公式表示为

$$B_i = \sum_{s \neq i \neq t} \frac{\sigma_{st}(i)}{\sigma_{st}}$$

式中: B_i 表示节点 i 的介数中心性, σ_{st} 是从节点 s 到节点 t 的最短路径数量, $\sigma_{st}(i)$ 是经过节点 i 的最短路径数量。

图 2 描述了 motif 结构特征, 展示了 3 种典型

结构。三角结构 (三节点环): $A \rightarrow B \rightarrow C \rightarrow A$; 星型结构: $D \rightarrow E, D \rightarrow F, D \rightarrow G$; 链式结构: $H \rightarrow I \rightarrow J$ 。




图 2 motif 结构特征

Fig. 2 motif structure feature

2.1.2 时间行为特征

在时间维度, 本文考虑节点发生时间戳, 构造时间窗标签 (例如交易周期分段)、时间差特征 (如两次交易间隔) 等行为模式特征。这些动态特征可揭示非结构性异常行为, 如短时间内频繁转账、突发高额交易等。其与结构特征形成互补, 有助于综合识别异常行为。最终, 将上述结构特征与原始交易特征进行拼接, 作为图神经网络建模的输入, 公式表示为

$$X' = \text{concat}(X, M, T)$$

图 3 给出了从原始时间戳到特征向量的转换过程, 包括时间戳的归一化处理和特征向量的生成, 清晰地解释了时间特征的归一化过程。




图 3 时间特征构建示意

Fig. 3 Schematic of time feature construction

2.2 多教师图神经网络模块

为提升图结构建模能力, 引入 GCN、GIN、GAT 和 GraphSAGE 这 4 类 GNN 模型作为教师模型, 分别从不同角度学习图结构表示, 增强模型对不同交易模式的建模能力。GraphSAGE^[3] 通过邻居采样与聚合进行归纳建模, 支持大规模图的采样训练, 具备良好的扩展性, 公式表示为

$$h_v^{(l+1)} = \sigma(W_1^{(l)} h_v^{(l)} + W_2^{(l)} \cdot \text{AGG}(\{h_u^{(l)}, \forall u \in N(v)\}))$$

式中: $h_v^{(l)}$ 表示节点 v 在第 l 层的特征向量; $W_1^{(l)}$ 和 $W_2^{(l)}$ 表示第 l 层的权重矩阵, 用于对节点特征和聚合的邻居特征进行线性变换; $\sigma(\cdot)$ 表示激活函数; $N(v)$ 表示节点 v 的邻居节点集合; AGG 表示聚合函数, 用于聚合邻居节点的特征。

GCN^[1] 以拉普拉斯矩阵为基础的半监督图卷积网络, 擅长捕捉局部平滑结构, 适合低扰动图, 公式表示为

$$h_i^{(l+1)} = \sigma \left(\sum_{j \in N(i) \cup \{i\}} \frac{1}{\sqrt{d_i d_j}} W^{(l)} h_j^{(l)} \right)$$

式中 d_i 表示节点 i 的度数。

GIN^[22] (graph isomorphism network) 使用 MLP 结构实现最大判别性的图嵌入, 具有较强的判别性, 能够精细地区分节点结构, 公式表示为

$$h_i^{(l+1)} = \text{MLP}^{(l)} \left((1 + \epsilon^{(l)}) \cdot h_i^{(l)} + \sum_{j \in N(i)} h_j^{(l)} \right)$$

式中: $\epsilon^{(l)}$ 表示第 l 层的可学习参数, $\text{MLP}^{(l)}$ 表示第 l 层的多层感知机。

GAT^[2] 引入自注意力机制, 能显式感知邻居节点的重要性, 公式表示为

$$h_i^{(l+1)} = \sum_{j \in N(i)} a_{ij}^{(l)} \cdot W^{(l)} \cdot h_j^{(l)}$$

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(a^T [W h_i || W h_j]))}{\sum_{k \in N(i)} \exp(\text{LeakyReLU}(a^T [W h_i || W h_k]))}$$

式中: α_{ij}^0 表示节点 i 和其邻居节点 j 之间的注意力系数, $\parallel$ 表示向量的连接操作。

每个教师模型生成其特有的节点表示, 通过高维图嵌入不仅参与后续蒸馏过程, 还能作为学生模型的输入特征之一, 从而帮助学生网络更好地继承图结构知识。表 1 对比了 4 种 GNN 教师模型的特性差异。各教师模型分别对输入图数据和节点特征学习生成高维图表示 (节点嵌入) 和软标签 (预测分布), 构成知识蒸馏的监督信号供学生模型学习与预测任务使用。 k 为采样邻居数, L 为网络层数, E 为图中边的数量, d 为节点特征的维度, V 为图中节点的数量。图 4 为多种 GNN 教师模型并行训练结构。

表 1 4 种 GNN 特性
Table 1 Four GNN Characteristics

模型	核心机制	使用场景	计算复杂度
GCN	频谱卷积	同质图	$O(E d)$
GAT	注意力聚合	异质关系	$O(V d^2 + E d)$
GIN	MLP聚合	拓扑结构	$O(L d^2)$
GraphSAGE	邻居采样	大规模图	$O(V kd)$




图 4 多种 GNN 教师模型并行训练结构

Fig. 4 Parallel training structure of multiple GNN teacher models

2.3 动态蒸馏与学生模型模块

不同于传统融合蒸馏 (如平均 soft label 或 ensemble), 本文采用多教师独立蒸馏机制, 即分别对 4 种 GNN 构建独立蒸馏路径, 使学生模型能够学习每种结构, 感知模型的差异化知识, 避免信息冲突与软标签模糊问题。同时引入动态权重融合策略, 进一步提升融合学习的自适应性与表达能力。

2.3.1 MLP 学生模型 (权重自适应)

图神经网络虽然具备强大的拓扑表征能力,

但在实际区块链金融风控系统的在线部署中面临 2 个严峻挑战: 一是推理延迟高; 二是冷启动与归纳推断困难, 当孤立的新交易产生时, GNN 往往难以直接处理。为解决上述痛点, 本文设计了一种基于动态蒸馏的 MLP 学生模型, MLP 的推理过程不涉及复杂的邻接矩阵乘法操作, 能够实现毫秒级的实时在线检测。同时, 通过本文设计的动态知识蒸馏机制, MLP 在训练阶段能够学习 GNN 教师模型提取的高阶图结构知识, 从而在推理阶段即便脱离图结构输入, 依然能保持对网络拓扑的隐含感知能力。在训练的初始阶段, 学生模型主要依赖于由图神经网络教师模型提供的软标签进行学习。随着训练的推进, 模型逐渐将学习重心转向真实标签, 通过一种自适应混合策略实现软硬标签的权重调整。学生模型的损失函数定义为

$$L_{\text{MLP}}(t) = \lambda(t) \cdot \text{CE}(\hat{\mathbf{y}}, \mathbf{y}) + (1 - \lambda(t)) \cdot \text{KL}(\hat{\mathbf{y}}, \mathbf{S})$$

式中: $\hat{\mathbf{y}}$ 表示模型预测的标签分布, $\mathbf{y}$ 为真实标签, $\mathbf{S}$ 为来自多个教师模型融合后的软标签。动态混合系数 $\lambda(t)$ 定义为

$$\lambda(t) = \frac{e^{-\gamma t}}{1 + e^{-\gamma t}}$$

式中: t 表示当前训练轮数, γ 是控制退火速率的超参数。该函数使得学生模型在训练早期更多依赖教师监督, 在后期逐步过渡到真实标签指导, 从而有效缓解对噪声软标签的过拟合问题。

MLP 的输入由 3 类特征拼接组成:

$$\mathbf{h}_t = \text{concat}(\mathbf{Z}^k, \mathbf{M}_t, \mathbf{T}_t)$$

式中: $\mathbf{Z}^k$ 表示来自第 k 个教师模型的图嵌入, $\mathbf{M}_t$ 为基于 motif 的结构特征向量, $\mathbf{T}_t$ 表示时间行为特征向量。

MLP 的输出为一个 logits 向量:

$$\mathbf{z}_t = \text{MLP}(\mathbf{h}_t)$$

为了获得最终的类别概率分布, 本文对 logits 向量应用 Softmax 函数:

$$\hat{y}_{t,i} = \frac{\exp(z_{t,i})}{\sum_{j=1}^C \exp(z_{t,j})}$$

式中: C 表示类别总数, $\hat{\mathbf{y}}_t = \text{Softmax}(\mathbf{Z}_t)$ 表示模型预测的类别概率分布向量。

2.3.2 RF 学生模型 (软标签增强)

本文还设计了一个基于随机森林的学生模型。将教师模型输出的软标签作为输入增强特征。该模型训练快速, 适合对比分析。随机森林由多个决策树组成, 模型对输入特征 $\mathbf{h}_v \in \mathbb{R}^d$ 执行多数投票预测:

$$\mathbf{y}_{\text{pred}} = \text{mode}(\{T_b(\mathbf{X})\}_{b=1}^B)$$

式中: T_b 表示第 b 棵决策树, B 是森林中的树数量。每棵树基于 Bootstrap 样本训练, 并通过 Gini 指数或信息增益构建划分。训练过程中学生模型接收教师输出的软标签作为伪标签。RF 学生模型训练时优化的目标为软标签拟合精度为

$$L_{\text{RF}} = \sum_{i=1}^N \text{CE}(\mathbf{y}_i, \hat{\mathbf{y}}_i)$$

式中: $\mathbf{y}_i$ 是教师网络输出的软标签, $\hat{\mathbf{y}}_i$ 是 RF 模型对第 i 个样本的预测结果。

2.4 鲁棒训练策略模块

区块链交易图常伴随结构噪声与类别极度不平衡问题, 为此本文引入 DropEdge 与 SMOTE 2 种机制提升训练鲁棒性。

2.4.1 DropEdge 策略

本文在图结构建模中引入 DropEdge 策略, 随机丢弃部分边, 以提升模型的泛化能力与结构鲁棒性, 如图 5 所示。




图 5 DropEdge 鲁棒增强示意

Fig. 5 Schematic of DropEdge robust enhancement

该方法能有效缓解图结构对异常噪声的过度依赖, 使 GNN 模型在邻接结构变化或部分缺失时仍保持稳定分类性能, 特别适用于区块链异常交易检测中“结构攻击”频发的高风险环境。为提升模型的泛化能力, 本文在图神经网络训练阶段加入 DropEdge 策略, 即每一轮训练随机丢弃一定比例的图边:

$$E' = \{(u, v) \in E \mid \text{rand}(u, v) > p\}$$

式中 p 为边丢弃率 (例如 20%), DropEdge 能有效避免过拟合邻居结构, 特别有助于 GCN 与 GAT 等邻居敏感模型的鲁棒性。

2.4.2 SMOTE 过采样

在样本层面, 使用 SMOTE 算法对少数类样本进行过采样, 构造合理的合成异常样本, 缓解类别分布倾斜问题, 提升模型在异常类别上的识别能力。

3 实验设置

3.1 实验环境与平台

为保证实验的稳定性与结果的可重复性, 所

有实验均在统一软硬件环境下进行, 并固定随机种子。具体环境配置如下: 实验平台操作系统为 Ubuntu 18.04, 开发语言为 Python 3.8.17, 深度学习框架采用 PyTorch 1.12, 并结合 CUDA 11.8 实现 GPU 加速计算。硬件配置方面, 使用 Intel(R) Core(TM) i7-9700 处理器, 搭载 GeForce RTX 2080 Ti 图形处理单元 (显存 10 GB), 系统内存为 32 GB。该配置为图神经网络等复杂模型的训练与评估提供了充足的计算支持和运行效率保障。

3.2 数据集介绍

本研究采用由 Elliptic 公司提供的 Elliptic Dataset, 该数据集因其高质量标注与真实的区块链交易结构, 成为当前区块链异常交易检测研究的权威数据集。该数据集广泛用于区块链交易追踪与金融风控领域, 主要包含 3 个部分。1) elliptic_txs_features.csv: 包含每笔交易的 166 维基础特征; 2) elliptic_txs_edgelist.csv: 区块链交易之间的有向图结构边列表; 3) elliptic_txs_classes.csv: 每笔交易的标签, 分为合法 (legal)、非法 (illegal) 与未知 (unknown)。数据的整体统计信息如表 2 所示。

表 2 Elliptic 数据集基本统计信息

Table 2 Basic statistical information of the elliptic dataset

类型	数量/条
总交易数	203 769
合法交易数	144 364
非法交易数	21 030
未知标签交易数	38 375
总边数(交易图)	234 355

考虑到区块链系统中的时间演化特性及模型在金融交易中的时序泛化能力, 本文将第 1~34 周的交易作为训练集, 第 35~49 周的交易作为测试集, 从而覆盖一个完整的交易周期, 并模拟现实业务场景中的时序漂移问题。

3.3 评价指标

为全面评估模型在区块链异常交易检测任务中的性能, 考虑到本文的区块链异常交易检测的目的是区分正常交易和异常交易, 因此采用常用的二分类评估指标, 包括准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall) 与 F1 值 (F1-score, F1)。在区块链交易场景中, 由于正常交易远多于非法交易, 数据存在严重类别不平衡问题, 此时仅使用准确率无法全面反映模型性能。因此, 精确率、召回率与 F1 在评估模型对非法交易识别能力方面尤为重要, 能够更客观、真实地反映模型

在异常检测任务中的实用价值。

4 实验分析

4.1 不同教师网络的对比效果

为评估不同 GNN 教师模型在动态知识蒸馏框架中的教学效能,本文选取 4 种 GNN 典型架构,分别与 RF 和 MLP 学生模型组合测试,比较其在区块链异常交易检测任务中的性能表现。实验结果如表 3 所示。

表 3 不同教师网络的对比效果
Table 3 Comparison effects of different teacher networks %

教师模型	学生模型	Accuracy	Precision	Recall	F1
GraphSAGE	RF	99.28	99.56	99.01	99.28
GraphSAGE	MLP	98.27	97.67	98.89	98.27
GIN	RF	99.30	99.55	99.05	99.35
GIN	MLP	98.14	97.57	98.74	98.15
GAT	RF	99.35	99.58	99.04	99.35
GAT	MLP	98.30	97.75	98.92	98.31
GCN	RF	99.41	99.71	99.10	99.38
GCN	MLP	98.02	97.46	98.62	98.03

注:表中各值为每类模型的平均值,保留两位小数。

实验结果表明,基于 RF 的学生模型在所有教师架构下均显著优于 MLP 学生模型,其平均 F1 提高了 1.13 个百分点,说明 RF 更具备学习 GNN 教师模型复杂决策边界的能力。在不同教师网络的比较中,传统 GCN 架构展现出优越的教学能力(F1=99.38%),优于 GAT、GIN 与 GraphSAGE。可能是由于 GCN 通过对称归一化拉普拉斯矩阵进行特征传播,较好地保留了交易图中的同质结构信息,适用于具有稠密连接与均匀关系的金融交易图。相比之下,GAT 引入注意力机制虽在小样本异质图中有效,但可能由于本研究中的边权重分布相对集中,其注意力机制的辨别能力未能充分发挥,最终 F1 略逊于 GCN(99.35%vs.99.38%)。GIN 理论上表达能力最强,但在本数据集上存在一定过拟合倾向,导致蒸馏效果未达到预期。

综上,实验表明,针对不同的特征或功能需求,各类教师模型展现出互补的教学优势:GCN 结构平滑,在同质化交易图中表现优异;GAT 善于捕捉异质图中的关键关系;GIN 则在复杂结构判别任务中潜力显著。因此,在实际应用中结合具体的数据特征与任务目标灵活选配教师模型,可以充分发挥其结构特性优势。

4.2 与经典模型的对比结果

为进一步验证所提出方法的有效性,本文选取在前节中表现最佳的 GCN-RF 组合(记为 MGDD(RF))作为代表模型,GCN-MLP 组合(记为 MGDD(MLP))作为辅助代表模型,与传统机器学习方法、深度学习模型、原始图神经网络模型及相关文献方法进行对比分析,包括 KNN(K-nearest neighbors)^[23]、LSTM(long short-term memory)^[24]、GNB(Gaussian naive bayes)^[24]、SVM^[25]、MLP^[26]、LR(logistic regression)^[26]、GAT^[2]、GCN^[1]、GIN^[22] 和 GraphSAGE^[3]。对比结果如表 4 所示。

表 4 本方法与经典模型不同指标对比
Table 4 Comparison of different indicators between this method and the classical model %

模型	Accuracy	Precision	Recall	F1
KNN ^[23]	91.91	58.63	55.17	56.85
LSTM ^[27]	97.70	88.86	87.71	88.28
GNB ^[24]	64.26	21.20	97.95	34.86
SVM ^[28]	91.27	54.57	57.06	55.79
MLP ^[25]	97.84	89.51	88.20	88.85
LR ^[26]	96.12	84.16	82.72	83.43
GAT ^[2]	91.80	67.10	33.62	44.80
GCN ^[1]	92.23	83.52	26.75	40.53
GIN ^[22]	90.01	16.67	0.22	0.43
SAGE ^[3]	95.10	83.37	63.05	71.80
MGDD(RF)	99.41	99.71	99.10	99.38
MGDD(MLP)	98.02	97.46	98.62	98.03

从表 4 看出,本文提出的 MGDD(RF) 模型在所有评估指标上均显著优于现有方法,F1 达到 99.38%,准确率达 99.41%,全面超越包括 LSTM、MLP、SVM 等主流检测方法。其中,传统机器学习方法普遍面临精度与召回率的失衡问题。例如,SVM 虽在准确率上达到 91.27%,但 F1 仅为 55.79%;高偏差模型如高斯朴素贝叶斯(GNB)表现更为极端,召回率虽接近 98%,但精度不足 22%,导致 F1 跌至 34.86%。

为了直观展示本方法与经典模型在不同指标上的表现差异,图 6 绘制了不同异常检测方法的召回率与精度对比雷达图。从图 6 可以看出,深度学习方法中,表现最好的 LSTM 模型 F1 为 88.28%,但在非法交易识别(即 Recall)上仍逊色于 MGDD 提出的蒸馏机制(提升了 10.9 百分点)。此外,原始 GNN 模型(GCN、GAT、GIN)在未引入样本增强和蒸馏机制的情况下,召回率均低于 35%,验证了直接在极度不平衡的原始图上训练 GNN 存在严重性能瓶颈。MGDD 框架动态知识蒸馏不仅提升模型性能,更具备良好的模型

压缩与泛化能力, 为金融风控系统提供了更可行的部署路径。




图 6 不同异常检测方法的召回率与精度对比雷达图

Fig. 6 Radar chart comparing the recall rate and accuracy of different anomaly detection methods

4.3 与现有文献典型方法的对比分析

为全面验证 MGDD 框架的先进性, 本文选取近年来具有代表性的欺诈检测方法进行对比, 包括特征增强型 (MFF(multi-feature fusion)^[29])、重采样型 (RRUF(robust resampling for unbalanced fraud detection)^[11])、图结构建模 (GAS(graph attention-based fraud detection with structure learning)^[30])、PBO(probabilistic bayesian optimization for graph construction)^[10] 等。对比结果如表 5 所示。

表 5 与其他文献不同指标对比

Table 5 Comparison with other literature metrics %

模型	Accuracy	Precision	Recall	F1
MFF	—	92.96	85.00	92.43
RRUF	97.86	94.59	71.10	90.02
GAS	98.11	94.01	85.48	89.54
PBO	—	98.50	66.00	79.00
MGDD(RF)	99.41	99.71	99.10	99.38
MGDD(MLP)	98.02	97.46	98.62	98.03

从表 5 中可以看出, MGDD(RF) 在 F1、Precision 和 Recall 3 项指标上显著优于现有方法。与最优文献方法 MFF 相比, MGDD(RF) 的 F1 提升了 6.95 百分点, Precision 达到 99.71%, Recall 达到 99.10%, 均达到了新的高度。此外, MGDD(RF) 的 Recall 与 Precision 差值仅为 0.61 百分点, 远优于 GAS(差值为 8.53), 表明其在精度与召回率之间实现了高度均衡。特征增强型的 MFF 依赖人工特征, Recall 表现 (85.00%) 较低, 难以覆盖隐匿性强的欺诈行为。重采样型的 RRUF 通过欠采样提高 Precision(94.59%), 但 Recall 降至 71.10%, F1 受限。

图 7 为现有文献方法与 MGDD 各指标对比

柱状图。可以看出, 像 GAS、PBO 这样的图结构型方法注重局部图特征, 缺乏全局建模能力, 整体判别能力偏弱。相比之下, MGDD 框架通过多层次图卷积与特征重组机制, 融合局部结构感知与全局分布平衡, 实现了协同优化策略。这表明了图数据蒸馏与特征增强联合建模在金融欺诈检测中的有效性。




图 7 现有文献方法与 MGDD 各指标对比

Fig. 7 Comparison of MGDD with literature methods

4.4 模块消融实验

为了更清楚地了解 MGDD 框架中各个关键模块的实际作用, 本文设计了一组模块消融实验。本文选取了 3 组具有代表性的“教师-学生”模型组合, 分别承担不同的评估任务: GCN-RF 作为主对照组, 因其最优的综合性能 (F1 为 99.38%) 和稳定性, 用于验证 SMOTE、DropEdge 等通用模块的普适性。GAT-MLP 作为敏感性测试模块, 利用 MLP 对参数变化的高敏感性以及 GAT 对图拓扑特征的强处理能力, 可高效分析 motif 模块、时间特征、图结构扰动等因素对模型判别能力的微调影响。GIN-RF 作为极端兼容组, GIN 模型在训练中具有有一定过拟合倾向, 而 RF 具备强表征吸收能力, 该组合用于评估 MGDD 框架在“结构异常”教师网络下的鲁棒性与泛化能力。

在具体操作上, 本文采用控制变量的方法, 依次移除或替换以下模块来观察性能变化: SMOTE 过采样 (用于解决样本不平衡)、DropEdge 正则化 (用于增强模型的鲁棒性) 以及知识蒸馏机制 (把教师模型的知识传给学生模型)。所有实验都使用相同的数据划分、图构建方法、随机种子和超参数, 保证结果公平、可比、可复现。

4.4.1 SMOTE 对不平衡样本的缓解效果

Elliptic 数据集中存在严重的类别不平衡, 非法交易仅占少数。为增强少数类样本的代表性, 本文在训练集中引入 SMOTE 过采样, 并评估其对学生模型性能的影响。实验结果如表 6 所示。

表 6 SMOTE 对不平衡样本的缓解效果
Table 6 SMOTE's effect on imbalanced data %

模型	有无SMOTE	Accuracy	Precision	Recall	F1
GCN-RF	有	99.41	99.71	99.10	99.38
GCN-RF	无	98.36	98.57	84.67	91.09
GAT-MLP	有	98.3	97.75	98.92	98.31
GAT-MLP	无	97.56	91.09	83.51	89.14
GIN-RF	有	99.30	99.55	99.05	99.35
GIN-RF	无	98.46	99.66	84.74	91.60

SMOTE 显著提升了所有模型的性能,尤其在召回率 (Recall) 方面表现突出。例如,GCN-RF 组合在引入 SMOTE 后,Recall 从 84.67% 提升至 99.10%,提升了 14.43 个百分点。同时,Precision 也从 98.57% 提升至 99.71%,未出现传统过采样方法中常见的“精度下降”现象。这表明,得益于图结构信息的引导,SMOTE 并未引入过多噪声或冗余样本,而是有效增强了决策边界附近的非法交

易表示,从而在提升召回率的同时保持甚至提升了判别精度。

其他模型组合,如 GAT-MLP 和 GIN-RF,也表现出相似的趋势。GAT-MLP 的 F1 从 89.14% 提升至 98.31%,而 GIN-RF 在原本性能已较强的基础上,将 F1 提升至 99.35%。尽管 GIN-RF 的 Precision 轻微下降 (从 99.66% 降至 99.55%),但 Recall 的大幅提升 (从 84.74% 至 99.05%) 使其综合性能显著改善,F1 分数提升了近 8 个百分点。

SMOTE 消融实验结果对比如图 8 所示,采用了 SMOTE 的模型各指标得分都远远高于未使用的。这表明 SMOTE 不仅显著提升了非法交易的识别能力,还有效避免了过拟合或性能下降等风险。结合图结构进行过采样,使得生成样本更贴近原始分布,有助于维持类间边界的几何一致性。该实验充分验证了 SMOTE 作为本框架中关键模块之一,在应对极端不平衡图数据时的有效性与通用性。




图 8 SMOTE 消融实验结果对比

Fig. 8 Comparison of the results of the SMOTE ablation experiment

4.4.2 DropEdge 对教师模型鲁棒性的影响

DropEdge 是一种结构正则化策略,在训练时随机丢弃图中的边,有助于提升模型对结构噪声的鲁棒性。如表 7 所示,DropEdge 技术对模型性能的影响呈现显著架构依赖性。在 GCN-RF 组合中,启用 DropEdge 带来 F1 的微小提升 (从 99.36% 提升到 99.38%),同时 Recall 提高 0.05 个百分点 (从 99.05% 提升到 99.10%),表明边丢弃策略增强了模型对少数类样本的识别能力。值得注意的是,GAT-MLP 组合受益更为明显,F1 提升了 0.42 个百分点,其中 Recall 增长 0.42 个百分点,验证了 DropEdge 对注意力机制模型的特殊价值。然而,GIN-RF 组合出现反直觉现象:禁用 DropEdge 时 F1 反而更高 (99.48%vs.99.35%)。

这种差异可能源于 GIN 的消息传递机制与边丢弃策略的互斥性——Weisfeiler-Lehman 测试依赖完整的邻域结构,随机删边会破坏其同构性判断。

表 7 DropEdge 对教师模型鲁棒性的影响
Table 7 DropEdge's impact on teacher model robustness %

模型	有无 DropEdge	Accuracy	Precision	Recall	F1
GCN-RF	有	99.41	99.71	99.10	99.38
GCN-RF	无	99.40	99.80	99.05	99.36
GAT-MLP	有	98.3	97.75	98.92	98.31
GAT-MLP	无	97.85	97.21	98.50	97.89
GIN-RF	有	99.30	99.55	99.05	99.35
GIN-RF	无	99.4	99.82	98.98	99.48

对比3组实验可得出重要结论:1)对基于注意力的GAT-MLP,推荐默认启用 $p=0.3$ (该值通过网格搜索确定为最适边丢弃)的DropEdge。2)对GIN架构建议关闭DropEdge或降低丢弃率。3)GCN-RF可灵活选择,边际收益与计算成本需权衡。

4.4.3 知识蒸馏对学生模型性能的影响

为评估知识蒸馏(通过软标签)对学生模型性能的提升效果,本文设计了对比实验,将仅使用硬标签训练的学生模型与引入教师软标签(soft label)的完整蒸馏版本进行性能比较,结果如表8所示。

表8 知识蒸馏对学生模型性能的影响
Table 8 Knowledge distillation's impact on student model performance %

学生模型	Accuracy	Precision	Recall	F1
去掉教师概率的RF	96.12	84.16	82.72	83.43
仅使用硬标签的GCN-MLP	97.76	96.92	98.66	97.78
完整的GCN-RF	99.41	99.71	99.10	99.38
完整的GCN-MLP	98.02	97.46	98.62	98.03

在MLP学生模型中,本文将原有的动态蒸馏策略替换为静态机制,即移除 α 的自适应调节过程,采用固定蒸馏权重,如 $\alpha=0.7$ ($\alpha=0.7$ 作为一个经过验证的固定值,能够在大多数情况下提供较好的结果),以测试权重调控对模型性能的影响。对于RF学生模型,其蒸馏机制体现为将教师输出的概率分布拼接进输入特征,若去除此部分,则构成无知识蒸馏的对照模型。

实验结果表明,在无教师指导的情况下,RF学生模型的F1仅为83.43%,而引入教师软标签后,GCN-RF模型达到99.38%,显示出软标签在提升分类边界判别力和特征表达能力方面具有决定性作用。相比之下,GCN-MLP即使不引入蒸馏,也能取得97.78%的F1,性能下降相对较缓,说明其对蒸馏的依赖性较低。然而,在引入软标签后仍获得0.25个百分点的提升,验证了软标签带来的泛化能力增强。图9给出了知识蒸馏对学生模型性能结果对比。

对比表4与表8可知:经过GCN软标签指导的RF,其性能产生了大幅提升,出现这种现象的原因在于特征学习空间的强正交互补性与软标签蕴含的暗知识。RF作为强大的非线性集成分类器,在接收了自身原始特征与GCN的软标签后,实际上完成了拓扑警示信号与局部统计规律的特

征级深度融合。GCN补齐了RF缺失的全局结构感知,RF则修正了GCN在不平衡数据上的分类阈值偏移。从而使这种机制打破了单个模型的性能瓶颈,证明了MGDD框架中异构知识蒸馏设计的科学性与必要性。




图9 知识蒸馏对学生模型性能结果对比

Fig. 9 Comparison of the performance results of student models by knowledge distillation

综上所述,知识蒸馏不仅在整体上提升了学生模型的准确率与泛化能力,尤其对基于树的随机森林模型表现出更强的适应性与依赖性。实验验证了软标签与结构指导之间的协同增强作用,有效提升了学生模型的学习能力与决策鲁棒性。

4.5 鲁棒性测试

为进一步验证模型是否真正从图结构和时间演化中学习到了识别异常交易的能力,而非依赖标签分布中的潜在偏置,本文设计了该消融实验。具体做法是在保持图结构和节点特征不变的前提下,随机打乱训练集中样本的标签顺序,从而人为破坏原始标签与图结构及时间特征之间的关联性,以测试模型在缺乏语义监督时的表现能力。实验结果如表9所示。

表9 标签打乱消融实验结果
Table 9 Results of the label shuffling ablation experiment %

学生模型	是否打乱标签顺序	Accuracy	Precision	Recall	F1
GCN-RF	是	50.20	50.11	48.68	49.38
GCN-RF	否	99.41	99.71	99.10	99.38
GCN-MLP	是	59.82	56.83	81.09	66.82
GCN-MLP	否	98.02	97.46	98.62	98.03

在打乱标签之后,所有模型的性能均显著下降,Accuracy和F1接近50%,表现与随机猜测相当,说明模型在正常训练条件下确实能够从结构与时序信息中学习具有判别力的特征。其中,RF学生模型对标签打乱更为敏感,在标签扰

动后准确率下降至 50.20%，召回率仅为 48.68%，几乎完全丧失分类能力；相比之下，MLP 学生模型在相同条件下仍保留部分判别能力（如 F1 为 66.82%），表明其在特征表达空间中具备更强的非结构化泛化能力。

根据实验数据，绘制了图 10 鲁棒性测试结果图，图中也可以看出，该消融实验充分验证了本文方法并非依赖训练标签的分布模式进行“记忆式拟合”，而是通过图神经网络对图结构与时序演化规律的有效建模，实现了对异常交易行为的深层判别。这也进一步凸显了所提方法在区块链异常交易检测任务中的泛化能力与鲁棒性优势。




图 10 鲁棒性测试结果

Fig. 10 Results of robustness tests

5 结束语

本文提出了一种基于多教师独立蒸馏的区块链异常交易检测方法——MGDD。该方法综合引入图结构特征（如 motif 模式）用于结构增强，同时采用 SMOTE 过采样技术有效缓解了区块链交易数据中的类别不平衡问题，在多个评估指标上显著优于传统方法。实验结果表明，基于异构 GNN 教师网络（GCN、GAT、GIN、GraphSAGE）的多教师架构能够从不同角度全面提取交易图中的高阶结构信息；此外，本文设计了 2 个学生模型进行独立学习，并通过蒸馏策略显著提升了它们的检测性能与泛化能力，尤其是 RF 模型，在蒸馏引导下准确率达到 99.41%。motif 特征与 SMOTE 采样的结合进一步增强了模型面对不平衡数据时的鲁棒性和稳定性，验证了其在区块链异常交易检测任务中的有效性和实用价值。

尽管取得了良好效果，本研究仍存在提升空间。未来工作拟在 MGDD 框架中引入超图（Hypergraph）结构对复杂交易进行原生建模，并探索使用超图上的随机游走算法（hypergraph random

walk）进行先期特征提取，以期更精准地发现跨长周期的、隐蔽的大规模协同异常交易行为，进一步增强模型在未知真实场景下的泛化与检测能力；同时，可结合跨图迁移学习和联邦蒸馏技术，提升模型在跨链环境下的泛化能力和隐私保护能力，从而拓展其在更复杂、动态及隐私敏感区块链场景中的应用潜力。

参考文献：

- [1] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[EB/OL]. (2016-09-09)[2025-10-08]. <https://arxiv.org/abs/1609.02907>.
- [2] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks[EB/OL]. (2017-10-30)[2025-10-08]. <https://arxiv.org/abs/1710.10903>.
- [3] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs[EB/OL]. (2017-06-07)[2025-10-08]. <https://arxiv.org/abs/1706.02216>.
- [4] WEBER M, DOMENICONI G, CHEN Jie, et al. Anti-money laundering in Bitcoin: experimenting with graph convolutional networks for financial forensics[EB/OL]. (2019-08-31)[2025-10-08]. <https://arxiv.org/abs/1908.02591>.
- [5] JULIUM M, LØLAND A, HUSEBY R B, et al. Detecting money laundering transactions with machine learning[J]. *Journal of money laundering control*, 2020, 23(1): 173-186.
- [6] PINNA A, TONELLI R, ORRÚ M, et al. A Petri nets model for blockchain analysis[J]. *The computer journal*, 2018, 61(9): 1374-1388.
- [7] ANDROULAKI E, KARAME G O, ROESCHLIN M, et al. Evaluating user privacy in bitcoin[C]//International Conference on Financial Cryptography and Data Security. Berlin: Springer Berlin Heidelberg, 2013: 34-51.
- [8] FARRUGIA S, ELLUL J, AZZOPARDI G. Detection of illicit accounts over the Ethereum blockchain[J]. *Expert systems with applications*, 2020, 150: 113318.
- [9] IBRAHIM R F, MOHAMMAD ELIAN A, ABABNEH M. Illicit account detection in the ethereum blockchain using machine learning[C]//2021 International Conference on Information Technology. Amman: IEEE, 2021: 488-493.
- [10] 王栋, 李达, 王合建. 基于深度 PCA 与贝叶斯优化的区块链异常交易检测[J]. *南方电网技术*, 2024, 18(9): 78-87, 105.
WANG Dong, LI Da, WANG Hejian. Blockchain abnormal transaction detection based on deep PCA and Bayesian optimization[J]. *Southern power system technology*, 2024, 18(9): 78-87, 105.
- [11] 朱会娟, 陈锦富, 李致远, 等. 基于多特征自适应融合的区块链异常交易检测方法[J]. *通信学报*, 2021, 42(5):

- 41–50.
ZHU Huijuan, CHEN Jinfu, LI Zhiyuan, et al. Blockchain abnormal transaction detection method based on adaptive multi-feature fusion[J]. *Journal on communications*, 2021, 42(5): 41–50.
- [12] CAI Jiahong, LIANG Wei, LI Xiong, et al. GTxChain: a secure IoT smart blockchain architecture based on graph neural network[J]. *IEEE Internet of Things journal*, 2023, 10(24): 21502–21514.
- [13] POURSAFAEI F, HAMAD G B, ZILIC Z. Detecting malicious ethereum entities via application of machine learning classification[C]//2020 2nd Conference on Blockchain Research & Applications for Innovative Networks and Services. Paris: IEEE, 2020: 120–127.
- [14] NERURKAR P. Illegal activity detection on Bitcoin transaction using deep learning[J]. *Soft computing*, 2023, 27(9): 5503–5520.
- [15] CHEN Weili, GUO Xiongfeng, CHEN Zhiguang, et al. Phishing scam detection on ethereum: towards financial security for blockchain ecosystem[C]//Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence. Yokohama: IJCAI, 2020: 4506–4512.
- [16] JOURDAN M, BLANDIN S, WYNTER L, et al. Characterizing entities in the Bitcoin blockchain[EB/OL]. (2018–10–29)[2025–10–08]. <https://arxiv.org/abs/1810.11956>.
- [17] RONG Yu, HUANG Wenbing, XU Tingyang, et al. DropEdge: towards deep graph convolutional networks on node classification[C]//International Conference on Learning Representations. New Orleans: OpenReview.net, 2019: 1–18.
- [18] TIAN Yijun, PEI Shichao, ZHANG Xiangliang, et al. Knowledge distillation on graphs: a survey[J]. *ACM computing surveys*, 2025, 57(8): 1–16.
- [19] YANG Yiding, QIU Jiayan, SONG Mingli, et al. Distilling knowledge from graph convolutional networks [EB/OL]. (2020–03–23)[2025–10–08]. <https://arxiv.org/abs/2003.10477>.
- [20] ZHOU Sheng, WANG Yucheng, CHEN Defang, et al. Distilling holistic knowledge with graph neural networks [EB/OL]. (2021–08–12)[2025–10–08]. <https://arxiv.org/abs/2108.05507>.
- [21] ZHANG Liying, SUN Haihang. ESA-GCN: an enhanced graph-based node classification method for class imbalance using ENN-SMOTE sampling and an attention mechanism[J]. *Applied sciences*, 2024, 14(1): 111.
- [22] XU Keyulu, HU Weihua, LESKOVEC J, et al. How powerful are graph neural networks?[EB/OL]. (2018–10–01)[2025–10–08]. <https://arxiv.org/abs/1810.00826>.
- [23] FIX E, HODGES J L. Discriminatory analysis. nonparametric discrimination: consistency properties[J]. *Revue internationale de statistique*, 1989, 57(3): 238.
- [24] DUDA R O, HART P E, STORK D G. Pattern Classification[M]. 2nd ed. New York: Wiley, 2001.
- [25] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. *Nature*, 1986, 323(6088): 533–536.
- [26] COX D R. The regression analysis of binary sequences [J]. *Journal of the royal statistical society series B (methodological)*, 1958, 20(2): 215–242.
- [27] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural computation*, 1997, 9(8): 1735–1780.
- [28] CORTES C, VAPNIK V. Support-vector networks[J]. *Machine learning*, 1995, 20(3): 273–297.
- [29] 林伟. 基于多特征融合的区块链异常交易检测[J]. *信息网络安全*, 2022, 22(10): 24–30.
LIN Wei. Detection of abnormal transactions in blockchain based on multi feature fusion[J]. *Netinfo security*, 2022, 22(10): 24–30.
- [30] 谭朋柳, 周叶. 基于 GAT 与 SVM 的区块链异常交易检测[J]. *计算机应用研究*, 2024, 41(1): 21–25, 31.
TAN Pengliu, ZHOU Ye. Blockchain anomaly transaction detection based on GAT and SVM[J]. *Application research of computers*, 2024, 41(1): 21–25, 31.

作者简介:



张铭泉, 副教授, 博士, 主要研究方向为机器学习、模式识别、系统结构, 发表学术论文 20 余篇。E-mail: mqzhang@ncepu.edu.cn。



贾文莉, 硕士研究生, 主要研究方向为深度学习、区块链、异常交易检测。E-mail: 2316823580@qq.com。



孟丽敏, 硕士, 主要研究方向为信息化建设与管理、网络信息技术、人工智能应用。E-mail: menglm@ncepu.edu.cn。