

基于人工智能的期货交易风险评估与预警方法

常飞¹, 王俊杰², 胡毅¹, 乔焰^{2,3}, 翁振昊², 郭金胜², 刘奕博², 李萌^{2,3}

(1. 徽商期货有限责任公司, 安徽 合肥 230002; 2. 合肥工业大学计算机与信息学院, 安徽 合肥 230601;

3. 合肥工业大学大数据知识工程教育部重点实验室, 安徽 合肥 230601)

摘要: 随着期货市场交易复杂性和系统性风险的不断攀升, 传统规则驱动的监管手段已难以有效识别高风险的交易行为。为此, 面向期货行业交易风险预警与市场监管的实际需求, 提出一种基于人工智能的期货交易风险评估与预警方法 (Fut-GAT-LSTM)。首先, 结合期货交易特点, 筛选可能引发市场动荡的多维度交易特征, 针对不同的特征类型设计了不同的交易特征嵌入方法, 并将嵌入的特征数据转换为时间序列图结构; 随后, 通过图注意力网络 (GAT) 建模交易图内部的空间依赖关系, 利用双向长短期记忆网络 (BiLSTM) 提取交易行为随时间演化的动态特征, 并基于交叉熵损失进行有监督训练; 最后, 通过训练后的模型计算每个交易节点的风险评分, 并利用动态阈值进行交易风险的预警。使用某大型期货公司提供的两组数据开展实验, 结果显示所提模型在 AUC 值、F1-score 等关键指标上均显著优于传统分类模型和神经网络基线方法, 在强平风险和 market 动荡风险检测任务中均表现出优异的性能。该方法为构建精准、高效、可扩展的智能期货市场监管系统提供了新思路, 具有良好的实际应用价值与推广前景。

关键词: 人工智能; 期货交易; 风险评估; 图注意力机制; 双向长短期记忆网络

中图分类号: F830.9

文献标志码: A

DOI: 10.11959/j.issn.2096-109x.2026005

AI-based risk assessment and early warning method for futures trading

Chang Fei¹, Wang Junjie², Hu Yi¹, Qiao Yan^{2,3}, Weng Zhenhao², Guo Jinsheng², Liu Yibo², Li Meng^{2,3}

1. Huishang Futures Co., Ltd., Hefei 230002, China

2. School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230601, China

3. Key Laboratory of Knowledge Engineering with Big Data, Hefei University of Technology, Hefei 230601, China

Abstract: With the increasing complexity of futures trading and rising systemic risks, traditional rule-based regulatory approaches can no longer effectively identify high-risk trading activities. In this paper, an artificial intelligence-based method for risk assessment and early warning in the context of futures trading risk monitoring and supervision, named Fut-GAT-LSTM, was proposed. Firstly, based on the characteristics of futures trading, multidimen-

收稿日期: 2025-06-23; 修回日期: 2025-12-11

通信作者: 胡毅, hyhf258@163.com

基金项目: 第十八期中期协联合研究计划课题; 中国证监会科技监管研究课题 (No.HSQHJSZX-2025-01); 国家自然科学基金 (No.62572168, No.62372149, No.U23A20303); 安徽省自然科学基金 (No.2508085MF151); 大数据知识工程教育部重点实验室开放课题 (No.BigKEOpen2025-04)

Foundation Items: The 18th CFA Joint Research Program, Research Project of China Securities Regulatory Commission's Technology Regulation (No. HSQHJSZX-2025-01), The National Natural Science Foundation of China (No. 62572168, No. 62372149, No. U23A20303), The Natural Science Foundation of Anhui Province (No. 2508085MF151), Open Project of the Key Laboratory of Knowledge Engineering with Big Data, Ministry of Education (No. BigKEOpen2025-04)

sional trading features likely to trigger market turbulence were selected. Different embedding methods were designed for different types of trading features, and the embedded feature data were transformed into a time-series graph structure. Subsequently, a graph attention network (GAT) was employed to model the spatial dependencies within the trading graph, while a bidirectional long short-term memory (BiLSTM) network was used to extract the temporal dynamics of trading behaviors evolved over time. The model was trained in a supervised manner based on cross-entropy loss. Finally, risk scores for each trading node were calculated by the trained model, and dynamic thresholds were utilized for risk early warning. Experiments conducted on two experimental datasets from a large futures company demonstrated that the proposed model significantly outperformed traditional classification models and baseline neural network approaches in key metrics such as AUC and F1-score, achieving superior performance in both forced liquidation risk detection and market turbulence risk detection tasks. This method offers a novel approach for building accurate, efficient, and scalable intelligent regulatory systems for the futures market, possessing strong practical value and application potential.

Keywords: artificial intelligence, futures trading, risk assessment, graph attention mechanism, bidirectional long short-term memory network

0 引言

信息技术的飞速发展在为期货市场带来交易效率提升、流动性增强和全球化互联的同时,也催生了新型的风险隐患。程序化交易、高频算法交易等技术的广泛应用,显著放大了市场的波动性与风险传导速度^[1]。例如,程序化交易可能因算法模型同质化或设计缺陷而发生“闪崩”^[2],而高频交易的瞬时大规模撤单行为则可能导致市场流动性短期枯竭和价格波动^[3]。此外,用户的频繁短线交易、大额单边持仓或跨市场套利操作,可能在杠杆作用下放大市场波动,甚至引发系统性风险^[4]。例如,在 2021 年美国“Game-Stop”事件中,散户通过社交媒体协调交易行为,在短期内推高股价并引发市场剧烈震荡。这类交易行为若出现在期货市场,同样会对市场的稳定运行构成潜在威胁。这些风险不仅体现在价格异常波动、流动性失衡等市场层面,还可能通过信用违约链条与跨市场风险传染效应对整个金融体系的稳定运行形成冲击^[5]。面对这些复杂且动态变化的风险,监管机构亟须构建更高效的监测体系,通过实时预警机制识别高风险交易行为,从而维护市场稳定和保护投资者的合法权益。

当前,期货市场风险预警主要依赖基于规则的静态阈值模型^[6],这类模型通常选取单一指标(单日交易量、持仓集中度等),通过设定固定阈值来判定交易行为是否异常。尽管该监管模式能够识别部分显性风险,但存在明显的缺陷:其

一,市场环境具有显著的动态性,固定阈值难以适配复杂多变的交易场景,在极端行情下(如正常的套保行为),合理的交易行为可能被误判为高风险操作;其二,传统基于规则的模型无法捕捉风险因子间多维度、非线性的关联特征,导致漏判率较高^[7]。例如,在程序化交易主导的市场环境中,高频交易者的行为模式可能突破传统阈值设定范畴,而监管系统却因规则僵化难以实施及时有效的干预。随着期货市场结构的日趋复杂、风险形态的愈发隐蔽,这种基于人工经验与简单规则的监管模式显现出响应滞后、效率低下的弊端,难以满足常态化风险防控的现实需求^[8]。

人工智能技术的日渐成熟,尤其是机器学习与大数据分析的突破性进展,为金融市场监管提供了新的解决方案。文献[9]利用异构图神经网络融合账户与设备的关联信息,实现了支付宝平台恶意账户的有效识别。文献[10]基于自组织映射算法分析客户交易记录,通过聚类异常模式识别信用卡欺诈交易行为。针对动态加密货币交易场景,NetWalk^[11]和 AddGraph^[12]等模型结合图卷积网络与时序建模(如门控循环单元)技术,能够有效捕捉动态图中的时空特征异常。文献[13]提出的基于 Transformer 的动态图异常检测框架(TADDY)引入 Transformer 自注意力机制,同时对节点的空间关系和时间演化规律进行建模,在比特币交易数据集的测试中准确率高达 94%。在反洗钱与非法金融资金检测方面,文献[14]提出基于边的子结构采样方法,结合时间和空间特征

的节点编码策略，利用动态图 Transformer 生成边嵌入向量，大幅提升了非法交易的识别能力。文献[15]提出的基于元学习的图偏差网络（meta-GDN）框架通过跨网络元学习实现了小样本场景下的跨平台非法交易检测。文献[16]提出基于边生成模型的 Goutlier 方法，通过分区节点并建立局部边模型检测非法金融账户。

然而，当前针对期货市场的异常交易检测方法仍存在显著不足。期货市场具有高杠杆、双向交易等特性，价格波动剧烈，且受交割月、合约流动性、跨市场套利等因素影响，期货交易行为模式的复杂度远超股票或传统金融交易^[17]。此外，程序化交易与高频策略的广泛应用，进一步放大了市场风险的复杂性与传导速度。现有异常交易检测模型往往难以适应期货交易中时序依赖性强、跨市场关联度高等风险特征。因此，亟须构建融合期货市场特性的新型人工智能模型，通过动态捕捉用户交易行为（如成交量、委托价格等）、用户财务特征（如持仓盈亏、保证金比例）及时间与周期性特征（如委托时间、成交时间）等维度的风险因子，结合图神经网络解析复杂交易行为特征，并引入自适应阈值机制，实现对程序化交易异常模式及市场操纵行为的精准预警，为期货市场监管提供智能化支持。为此，本文聚焦于构建基于人工智能的期货市场监管框架，重点解决两大核心问题：其一，针对异构的期货交易数据集进行融合处理与特征工程，建立用户交易行为与市场系统性风险的耦合分析模型；其二，设计动态风险阈值生成机制，实现对程序化交易异常模式与大额投机行为的精准识别，为监管部门提供可解释、可操作的预警决策支持。

1 期货交易数据特征分析

期货交易具有高杠杆、双向交易和复杂市场联动性等特点^[18]，其风险特征需从多维度数据中挖掘。本节基于多维期货交易数据（如委托交易明细、账户资金与风险指标、强平与结算信息等），对特征进行分类与关联分析，筛选关键风险因子并生成融合特征，为后续风险预警模型的构建提供数据基础。

根据期货交易业务逻辑与风险识别需求，本文将期货交易风险识别关键特征划分为表1所示

的4类，并筛选出与异常交易识别高度相关的核心特征。

表1 期货交易风险识别关键特征

特征类型	特征名称	特征取值
交易行为特征	买卖方向	买、卖
	开平仓标志	开仓、平仓
	委托量	实际数值
	短期成交量	实际数值
	长期成交量	实际数值
	委托价格	实际数值
	委托单状态	全部成交、部分成交、撤单
	期货合约代码	实际类型
账户财务特征	交易所保证金	实际数值
	公司保证金	实际数值
	账户权益	实际数值
	平仓盈亏	实际数值
	持仓盈亏	实际数值
	公司风险度	实际数值
	交易所风险度	实际数值
时间与周期特征	交易时间	实际时间
	委托时间	实际时间
	成交时间	实际时间
异常标志特征	用户强平标志	是、否
	大额/频繁报撤标志	是、否
	持仓限额标志	是、否
	大户报告标志	是、否

如表1所示，决定期货交易风险的关键特征类型包括交易行为特征、账户财务特征、时间与周期特征和异常标志特征。下面介绍每类特征所包含的核心特征。

1.1 交易行为特征

买卖方向：若存在频繁的反向操作，可能暗示对冲行为异常或存在市场操纵意图。

开平仓标志：频繁开仓而不平仓容易形成集中持仓，在临近交割期时易引发交割风险。

委托量/成交量：单笔大额交易或短时间高频交易，可能引发市场流动性骤变。

委托价格：以极端价格进行委托（远高于/低于市场价），可能试图通过“价格冲击”制造虚假流动性。

委托单状态：频繁撤单（如“已撤销”状态占比过高）可能暗示试探性交易或恶意刷单。

期货合约代码：该代码包含交易品种与到期日信息，有助于识别特定合约是否存在价格剧烈波动、持仓过度集中或其他交易异常等情况。

1.2 账户财务特征

交易所保证金：保证金不足（如低于交易所规定阈值）可能触发强制平仓，导致市场集中抛压。

公司保证金：当公司保证金不足时，表明客户已经接近甚至突破期货公司的风控红线。

账户权益：权益值波动剧烈（如单日亏损率超 50%）可能暗示账户存在异常操作。

平仓盈亏/持仓盈亏：平仓盈亏与持仓盈亏的反向关联（如平仓持续盈利而持仓持续亏损）可能暗示账户通过频繁平仓掩盖真实风险。

公司风险度：当公司风险度接近或超过 100% 时，表明客户已面临较高的穿仓风险。

交易所风险度：当交易所风险度达到或超过 100% 时，意味着客户保证金已低于交易所规定的最低要求，可能被交易所或期货公司依法执行强制平仓。

1.3 时间与周期特征

交易时间/委托时间/成交时间：交割日前后（如最后交易时间前 3 日）的高频交易可能引发交割集中风险。

1.4 异常标志特征

用户强平标志：强平标志为“是”的账户可能因保证金不足已被系统强制平仓，需结合其持仓盈亏分析强平原因。

大额/频繁报撤标志：大额报撤单可能通过虚假申报干扰价格（如价格冲击），制造市场流动性假象。高频报撤单可能通过“噪声攻击”干扰市场正常报价，在低流动性产品中影响更加显著。

持仓限额标志：持仓超限的账户可能通过集中持仓来影响价格。在临近交割月时，持仓超限账户可能通过非正常交易（如大额报撤单）操纵交割结算价。

大户报告标志：大户频繁调整持仓（如通过频繁报撤单或大额报撤单），可能暗示其试图通过隐蔽操作影响市场价格。

2 基于人工智能的期货交易风险预警模型

2.1 问题描述

设期货交易历史数据集 $V = \{v_1, v_2, \dots, v_N\}$ 包含 N 笔连续时间的交易记录，每笔交易记录 $v_i \in V$ 包含属性集合 $X_i = \{x_{i1}, x_{i2}, \dots, x_{iF}\}$ ，如 $x_{i1} \in \{0, 1\}$ 表示交易 v_i 的买卖方向、 $x_{i2} \in \mathbb{R}$ 表示该笔交易的委托量等。本文旨在构建人工智能模型 f_θ ，通过学习期货交易历史数据集 V 中蕴含的时间与空间特征，使模型能够对每笔最新发生的交易 v_j 输出其可能造成市场动荡的风险指数 y_j 。

2.2 期货交易特征工程

在构建基于交易节点的图模型之前，需对原始期货交易数据进行系统化预处理，为后续图结构构建和模型训练提供高质量的输入数据。考虑到期货交易特征数据的复杂性，本文先按照特征数值类型对特征进行分类，再针对不同类型的特征设计最优的特征嵌入方案。

针对表 1 所列的期货交易关键特征，本文将其划分为四大类：①数值类型特征，如委托量、交易所保证金、委托价格、持仓盈亏等；②离散类型特征，如买卖方向、开平仓标志、用户强平标志、大户报告标志等；③时间戳类型特征，如交易时间、委托时间、成交时间等；④混合类型特征，如期货合约代码。

各类型特征的处理方式如下。

1) 数值类型特征的处理：对数值类型的特征 x 进行归一化处理，计算式如下：

$$x' = \frac{x - \mu}{\sigma} \quad (1)$$

其中， μ 和 σ 分别为属性 x 的均值和方差。此操作的优势体现在两个方面：一方面能够有效消除不同特征间的量纲和取值范围差异，避免模型过度依赖数值较大的变量；另一方面有助于加快模型的训练收敛速度，提升模型的稳定性。

2) 离散类型特征的处理：对于二值离散类型特征，采用独热（one-hot）编码将其转换为二进制向量（如“0”表示买，“1”表示卖）。这样能将类别信息转化为模型可以处理的数值形式，同时避免引入不存在的“大小关系”（若直接用“0”和“1”表示买与卖，模型可能误认为“卖”的语义权重高于“买”），从而确保语义的准确

性和计算逻辑的合理性。对于多值离散型特征（如产品类型），使用低维嵌入向量表示，将高维稀疏的类别空间映射到低维稠密的向量空间。该方法不仅能够显著降低模型输入维度，还可以自动学习并保留不同类别间的相似性与关联关系。

3) 时间戳类型特征的处理：对于委托时间、成交时间等时间戳类型的特征，将其统一转换为标准格式（如 YYYY-MM-DD、HH:MM:SS）。这样处理一方面能够消除数据来源不一致导致的解析歧义，另一方面能够还原市场事件发生的先后顺序，为后续动态图模型的时序关联构建奠定基础。

4) 混合类型特征的处理：所谓混合类型是指该类特征包含两种以上类别属性。例如，期货合约代码既包含期货交易产品代码，又包含到期年月。例如，合约代码 rb2510，表示 2025 年 10 月到期的螺纹钢合约。研究人员设计了结构化解耦与分层嵌入（structural decomposition and hierarchical embedding, SDHE）表示方法用来处理混合类型特征。SDHE 的执行逻辑如下：首先将混合类型特征解耦为多个语义子成分，然后将各子成分对齐并分别嵌入，最后通过融合策略将不同子成分的嵌入向量映射至统一的特征空间。SDHE 解决了传统单一嵌入方法在新样本泛化能力上的局限性。

2.3 动态图模型构建

为确保模型能够学习到交易之间的时间与空间相关性特征，本节将交易数据组织成动态图模型。为体现交易之间的时间相关性，将连续时间轴划分为等长窗口 $\{T_1, T_2, \dots, T_K\}$ ，每个窗口 T_k 包含时间段 $[t_k, \Delta t]$ 内的所有交易 V^{T_k} 。其中 Δt 为窗口大小，该参数可以根据业务需求灵活设定。例如，将其设定为 5 min、1 h、1 天等，分别适配短时高频交易模式分析或长期交易趋势研判等不同场景。

为体现交易之间的空间相关性特征，针对每个时间窗口 T_k 构建图模型 $G^{T_k} = \{V^{T_k}, E^{T_k}, X^{T_k}, W^{T_k}\}$ 。节点集合 $V^{T_k} = \{v_1^{T_k}, v_2^{T_k}, \dots, v_{N_k}^{T_k}\}$ 表示当前时间窗口内的所有交易。 $E^{T_k} = \{e_1^{T_k}, e_2^{T_k}, \dots, e_{M_k}^{T_k}\}$ 表示交易之间的连边。边的构建规则如下：若交易 $v_i^{T_k}$ 与 $v_j^{T_k}$

由同一用户发起，且两笔交易的发起时间间隔 $|\tau_i - \tau_j| < \Delta t$ ，则在节点 $v_i^{T_k}$ 与 $v_j^{T_k}$ 之间建立连边，表示两笔交易之间存在较强的关联。 $X^{T_k} = \{x_1^{T_k}, x_2^{T_k}, \dots, x_{N_k}^{T_k}\}$ 表示节点 V^{T_k} 的属性矩阵。 W^{T_k} 为边的权重矩阵，其中权重 $w_{ij} \in W^{T_k}$ 由时间间隔衰减指数计算得到，如式(2)所示。

$$w_{ij} = \exp(-\lambda|\tau_i - \tau_j|), \lambda > 0 \quad (2)$$

其中， τ_i 和 τ_j 分别表示以 w_{ij} 为边权重的两笔交易的发起时间。通过上述方式，每个时间窗口对应一张静态图，沿时间轴排列的窗口图序列即构成完整的交易动态图序列 $\mathbf{g} = \{G^{T_1}, G^{T_2}, \dots, G^{T_K}\}$ 。

2.4 期货交易风险预警模型构建

本文提出一种融合图注意力网络（graph attention network, GAT）^[19]与双向长短期记忆网络（bidirectional long short-term memory network, BiLSTM）^[20]的期货交易风险评估与预警模型（Fut-GAT-LSTM）。该模型通过 GAT 模块捕捉交易图内部的空间相关性特征，通过 BiLSTM 模块建模图序列的时间演化规律，最终输出每个交易节点的风险评分。下面从模型结构、训练目标、检测方法及异常评分公式展开说明。

2.4.1 模型整体结构

基于人工智能的期货交易风险评估与预警模型 Fut-GAT-LSTM 的整体架构如图 1 所示。该模型由 GAT、BiLSTM 和交易风险评估与预警三大功能模块构成。GAT 模块用于学习交易节点之间空间相关性，BiLSTM 模块用于建模图序列时间依赖性，交易风险评估与预警模块用于检测交易风险。模型的处理流程如下：首先，将动态图序列 $\mathbf{g} = \{G^{T_1}, G^{T_2}, \dots, G^{T_K}\}$ 输入至 GAT 模块，该模块将每个图结构嵌入至低维隐空间，生成对应的图嵌入向量序列 $\mathbf{H}_L$ ；随后，将该隐向量序列输入 BiLSTM 模块，BiLSTM 模块提取隐空间向量 $\mathbf{H}_L$ 的时间相关性特征，生成融合时空特征的隐向量 $\mathbf{Z}_T$ ；最后，将隐向量 $\mathbf{Z}_T$ 输入交易风险评估与预警模块，经过全连接层完成特征维度转换与非线性映射，再通过 Softmax 层将其映射至风险指数区间 $Y \in \mathbb{R}^n$ 。其中，风险指数越高，意味着该笔交易引发市场动荡的潜在风险越大。




图 1 Fut-GAT-LSTM 的整体架构

2.4.2 基于 GAT 的期货交易空间特征嵌入

GAT 模块包含 L 层注意力层, 假设第 l 层第 i 个交易节点的输入特征为 $\mathbf{h}_i^{(l)}$, 当 $l=0$ 时, $\mathbf{h}_i^{(0)} = x_i$ (即原始节点特征), $j \in \mathcal{N}(i)$ 为第 i 个交易节点的邻居交易节点, 通过式(3)和式(4)可以得到每笔交易在第 l 层的注意力分数。

$$e_{ij}^{(l)} = \text{LeakyReLU}(\mathbf{a}^{(l)\top} [\mathbf{W}^{(l)} \mathbf{h}_i^{(l)} \parallel \mathbf{W}^{(l)} \mathbf{h}_j^{(l)}]) \quad (3)$$

$$\mathbf{a}_{ij}^{(l)} = \frac{\exp(e_{ij}^{(l)})}{\sum_{k \in \mathcal{N}(i)} \exp(e_{ik}^{(l)})} \quad (4)$$

其中, $\text{LeakyReLU}()$ 为激活函数, $\mathbf{W}^{(l)} \in \mathbb{R}^{d' \times d}$ 表示可学习的权重矩阵, $\mathbf{a}^{(l)} \in \mathbb{R}^{2d'}$ 表示注意力机制的可学习参数向量, $\parallel$ 表示向量拼接操作。随后, 下一层的节点特征表示可更新为:

$$\mathbf{h}_i^{(l+1)} = \sigma \left(\sum_{j \in \mathcal{N}(i)} \mathbf{a}_{ij}^{(l)} \mathbf{W}^{(l)} \mathbf{h}_j^{(l)} \right) \quad (5)$$

其中, $\sigma()$ 为激活函数。经过 L 层注意力层后, 每个图 G^{T_k} 可以嵌入表示为:

$$\mathbf{H}^{T_k} = \text{READOUT}(\{\mathbf{h}_i^{(L)} | i \in V^{T_k}\}) \quad (6)$$

其中, $\text{READOUT}()$ 为注意力聚合操作。

2.4.3 基于 BiLSTM 的时序特征提取

在将每个时间段的图结构 $\mathbf{g} = \{G^{T_1}, G^{T_2}, \dots, G^{T_k}\}$ 表示为图嵌入向量 $\mathbf{H} = \{\mathbf{H}^{T_1}, \mathbf{H}^{T_2}, \dots, \mathbf{H}^{T_k}\}$ 后, BiLSTM 模块将捕捉交易行为的时间依赖性。设

前向 LSTM 在时刻 T_k 的隐藏状态为 $\overrightarrow{\mathbf{h}}_{T_k}$ 、后向 LSTM 在时刻 T_k 的隐藏状态为 $\overleftarrow{\mathbf{h}}_{T_k}$, 二者可以通过式(7)和式(8)计算得到。

$$\overrightarrow{\mathbf{h}}_{T_k} = \text{LSTM}_{\text{forward}}(\mathbf{H}^{T_k}, \overrightarrow{\mathbf{h}}_{T_k-1}) \quad (7)$$

$$\overleftarrow{\mathbf{h}}_{T_k} = \text{LSTM}_{\text{backward}}(\mathbf{H}^{T_k}, \overleftarrow{\mathbf{h}}_{T_k+1}) \quad (8)$$

通过拼接前向与后向的隐藏状态, 最终生成嵌入时序依赖性的双向拼接特征, 如式(9)所示。

$$\mathbf{Z}_{T_k} = [\overrightarrow{\mathbf{h}}_{T_k} \parallel \overleftarrow{\mathbf{h}}_{T_k}] \quad (9)$$

对于期货交易的动态图序列 $\mathbf{g} = \{G^{T_1}, G^{T_2}, \dots, G^{T_k}\}$, 其对应的时空特征向量为 $\mathbf{Z} = \{\mathbf{Z}_{T_1}, \mathbf{Z}_{T_2}, \dots, \mathbf{Z}_{T_k}\} \in \mathbb{R}^{N_k \times T_k}$ 。

2.4.4 期货交易风险评估与预警

交易风险评估与预警模块由多层感知机 (multi-layer perceptron, MLP) 和 Softmax 激活函数 (σ) 组成。对于输入的时空特征向量 $\mathbf{Z} = \{\mathbf{Z}_{T_1}, \mathbf{Z}_{T_2}, \dots, \mathbf{Z}_{T_k}\}$, 计算每个特征向量的风险评分, 如式(10)所示。

$$\hat{y}_{T_k} = \sigma(\text{MLP}(\mathbf{Z}_{T_k})) \quad (10)$$

其中, $\hat{y}_{T_k} \in [0, 1]^{N_k}$ 表示交易集合 $V^{T_k} = \{v_1^{T_k}, v_2^{T_k}, \dots, v_{N_k}^{T_k}\}$ 的风险评分。评分越接近 1, 表示该交易的风险越大。

为对高风险交易的实时预警，本文采用动态阈值法自适应地调整风险阈值，对风险评分超过阈值的高风险交易进行预警，以引起监管部门重视。设定滑动窗口 w （如 1 min、1 h 或 1 天），利用式(11)计算其分数位阈值 θ_t 。

$$\theta_t = \text{Quantile}_{(q)}(\hat{y}_{t-w:t-1}) \quad (11)$$

其中， θ_t 表示当前时刻 t 的风险阈值为在 $t-w$ 到 $t-1$ 时段所有交易的前 $1-q$ 的最低评分。例如，当 $q = 0.95$ 时，异常阈值为 $t-w$ 到 $t-1$ 时段风险评分在前 5% 的最低评分。

2.4.5 模型训练

对于一组历史交易数据集 $V = \{v_1, v_2, \dots, v_N\}$ ，其风险标识为 $Y = \{y_1, y_2, \dots, y_N\} \in \{0, 1\}^N$ ，经过上述图构建与模型处理后，其生成的高风险预警标识为 $\hat{Y} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_N\} \in \{0, 1\}^N$ ，为使模型生成的风险标识逼近真实风险标识，采用式(12)所示的交叉熵损失函数，通过反向传播算法和基于 Adam 优化器的梯度下降方法对 GTA、BiLSTM 与 MLP 中的可训练参数进行优化，最终得到训练好的期货交易风险评估与预警模型：

$$\mathcal{L} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (12)$$

3 实验

本节在两个期货交易数据集上开展大规模实验，旨在全面评估本文提出的期货交易风险评估与预警模型（Fut-GAT-LSTM）的性能。实验通过与多种具有代表性的基线方法进行对比分析，验证所提模型的有效性与优越性。

3.1 数据集

实验数据来源于某大型期货公司在不同时间段、面向不同用户群体收集的两组具有不同特征的历史交易记录。两个数据集均包含手工标注的异常交易行为样本（强制平仓高风险交易与市场动荡高风险交易），具体如下。

1) FutData23 数据集：该数据集包含 12 000 个异常交易样本和 100 余万个正常交易样本。数据集划分如下：选取 2023 年 1—9 月的交易样本作为训练集用于训练模型；选取 2023 年 10 月的交易样本作为验证集，用于防止训练过程中的过拟合；选取 2023 年 11—12 月的交易样本作为测试

集，用于验证模型性能。

2) FutData25 数据集：该数据集包含约 70 743 个异常交易样本、70 余万个正常交易样本。该数据集包含更高频的交易行为（4 天内 70 万笔交易）数据。数据集划分如下：选取 2025 年 8 月 8—9 日的交易样本作为训练集用于训练模型；选取 2025 年 8 月 10 日的交易样本作为验证集，用于防止训练过程中的过拟合；选取 2025 年 8 月 11 日的交易样本作为测试集，用于验证模型性能。

为保障客户隐私与数据合规性，所有账户标识和关键字段已进行脱敏处理，此操作不影响交易行为模式与统计特征的分析。实验数据以天为单位进行划分，并据此构建时间序列图数据。

3.2 实验参数设置

本文模型使用 PyTorch 实现，模型训练使用硬件配置为 24 GB GPU (GeForce RTX 3090) 和 Intel Xeon Silver 4214R CPU @ 2.40GHz 的服务器。实验主要的参数设置如表 2 所示。

表 2 实验主要的参数设置

参数名称	取值
图注意力层数	3 层
注意力头数（每层）	4 头
隐空间维度数	128 维
Dropout 率	0.1
学习率	0.01
批次大小	32
最大训练轮数	100 轮
优化器	Adam
早停机制	5 轮无改善则终止

3.3 评价指标与基准方法

本文采用以下指标评估模型在交易风险评估与预警任务中的性能。

1) 精确率 (Precision)：预测为异常的交易样本中实际为异常的样本比例。

2) 召回率 (Recall)：模型成功识别出来的异常交易样本占有所有真实的异常交易样本的比例。

3) F1 分数 (F1-score)：精确率与召回率的调和均值。

4) AUC 值 (ROC 曲线下的面积)：衡量分类

器区分能力的标准。

为验证本文所提方法的优点,选择以下4种具有代表性的模型进行性能对比。

1) DAGMM^[21]: 利用自编码器为每个输入数据生成低维表示和重构误差,在此基础上将结果送入高斯混合模型,并对自编码器和高斯混合模型中的参数进行联合优化。

2) LSTM-VAE^[22]: 通过引入基于进度的先验分布来融合信号并重构其期望分布。当基于重构的异常评分高于状态的阈值时, LSTM-VAE的检测器会报告异常。

3) FGAN^[23]: 为解决现有方法只能在无污染的数据集下进行训练的问题, FGAN在训练神经网络之前使用伪标签过滤可能的异常样本,从而尽可能精确地捕获正常数据的分布,识别出异常样本。

4) TranAD^[24]: 该模型采用 Transformer 结构,利用注意力机制学习数据多模态的特征,并结合自调节机制与对抗训练实现鲁棒的异常检测。

3.4 实验结果分析

3.4.1 异常交易检测效果

对用户的强平风险进行准确的检测,有助于期货监管部门及时提醒期货公司防范用户交易风险,避免造成较大的资金损失。本文提出的 Fut-

GAT-LSTM与4种基线方法在强平风险检测任务上的实验结果见表3,从中可以看出, Fut-GAT-LSTM在 FutData-23与 FutData-25两个数据集上的 Precision、Recall、F1-score和 AUC值全面优于基线方法,其中 F1-score相较于最优基线方法分别提升4.88%和5.6%,展现出优异的检测性能。实验结果证明,面对高维度的复杂期货交易数据,本文方法在强平风险检测中相较于基线方法具有显著优势。

对市场动荡风险进行准确检测,有助于期货市场监管部门及时了解客户投资可能造成的市场动荡风险,从而提醒期货公司及时撤销交易,避免造成剧烈的市场动荡。Fut-GAT-LSTM与4种基线方法在市场动荡风险检测任务上的实验结果见表4,从中可以看出,本文方法在两个数据集上的 Precision、Recall、F1-score和 AUC值均优于基线方法,其中 F1-score值相较于最优基线方法分别提升3.13%和3.18%。实验结果证明,本文方法在市场动荡风险检测中相较于基线方法具有明显优势。

3.4.2 消融实验

为验证本文设计的 Fut-GAT-LSTM模型中各核心模块的有效性与必要性,研究人员开展了消融实验,在完整模型的基础上通过移除不同的组件构建了3种变体模型,具体如下。

表3 强平风险检测实验结果

方法	FutData23				FutData25			
	Precision	Recall	F1-score	AUC	Precision	Recall	F1-score	AUC
DAGMM	089.22%	61.76%	0.7305	0.7987	91.31%	60.42%	0.7479	0.7762
LSTM-VAE	75.91%	86.50%	0.8084	0.8873	76.23%	83.26%	0.7961	0.8631
FGAN	93.45%	92.72%	0.9308	0.9822	94.33%	91.65%	0.9301	0.9776
TranAD	96.60%	85.54%	0.9070	0.9750	97.75%	83.37%	0.8999	0.9692
Fut-GAT-LSTM	96.95%	98.31%	0.9762	0.9989	99.73%	96.75%	0.9822	0.9897

表4 市场动荡风险检测实验结果

方法	FutData23				FutData25			
	Precision	Recall	F1-score	AUC	Precision	Recall	F1-score	AUC
DAGMM	77.93%	89.20%	0.8333	0.8941	73.32%	85.15%	0.7878	0.8267
LSTM-VAE	73.18%	92.13%	0.8158	0.8709	71.11%	90.25%	0.7953	0.8432
FGAN	88.79%	86.63%	0.8766	0.9358	84.12%	83.90%	0.8403	0.9019
TranAD	96.91%	92.52%	0.9468	0.9847	93.87%	89.92%	0.9182	0.9531
Fut-GAT-LSTM	97.42%	97.87%	0.9764	0.9994	96.43%	93.10%	0.9474	0.9897

1) w/o (without) GAT: 移除用于捕捉交易数据空间相关性的GAT模块,改用全连接层处理空间信息,以验证GAT模块的作用。

2) w/o (without) BiLSTM: 移除用于学习交易数据时间相关性的BiLSTM模块,改用均值对数据进行池化,以验证BiLSTM模块的作用。

3) w/o (without) G: 移除动态图序列构建模块,改用简单的向量嵌入,以验证动态图序列的作用。

在FutData23和FutData25数据集上的消融实验结果分别见表5和表6,从表中数据可以看出,分别移除本文设计的3个模块,无论是强平风险的检测效果还是市场动荡风险的检测效果都会大幅下降。此结果充分验证了本文所设计模块的合理性和有效性。从表5中的数据可以看出,在FutData23数据集上,GAT模块的移除对模型检测性能的影响最大,这是因为GAT模块的设计充分考虑了数据的空间相关性,而期货交易的空间相关性特征(如同一个用户发起的不同交易)在很大程度上会影响交易风险的判断;BiLSTM模块的移除同样引发了模型检测性能的显著下降,其影响程度仅次于GAT模块。这表明交易之间的时间相关性(如短时间内的频繁交易)同样是风险评估的重要依据。动态图序列构建模块的移除对模型检测性能的影响相对来说最小,但

是其同样对检验结果起到了重要作用。从表6中的数据来看,在FutData25数据集上,移除BiLSTM模块导致了最显著的模型检测性能下降,这一结果证明,在高频交易场景下,短期时间依赖特征是风险识别的关键信号。相对而言,移除GAT模块和动态图序列构建模块虽同样会引起模型检测性能的显著下降,但其影响程度相对较小。不过,在对空间关联性更加敏感的市场动荡风险检测任务中,这两个模块的重要性更加凸显,占据了主导地位。综合两个数据集的消融实验结果可以得出,GAT、BiLSTM与动态图序列构建模块在期货交易风险评估中扮演着互补且不可或缺的角色。此结果充分印证了本文模型设计的合理性与普适性。

3.4.3 特征贡献度分析

为增强模型的可解释性,并揭示其在风险检测过程中关注的关键因素,本节对Fut-GAT-LSTM模型进行了特征层面的归因分析。具体而言,将Fut-GAT-LSTM模型在式(3)中学习到的注意力权重 α 映射回每个特征上,经过归一化处理后,统计各特征在强平风险与市场动荡风险两类检测任务中所分配的注意力权重,以量化不同特征对模型决策的贡献度。在FutData23数据集上的实验结果如图2所示。

实验结果表明,在市场动荡风险检测任务

表5 在FutData23数据集上的消融实验结果

变体模型	强平风险检测				市场动荡风险检测			
	Precision	Recall	F1-score	AUC	Precision	Recall	F1-score	AUC
w/o GAT	85.74%	79.53%	0.8256	0.8802	78.41%	85.03%	0.8157	0.8740
w/o BiLSTM	85.39%	87.54%	0.8640	0.9247	81.96%	89.23%	0.8546	0.9035
w/o G	89.84%	93.47%	0.9166	0.9455	91.35%	91.77%	0.9156	0.9771
Fut-GAT-LSTM	96.95%	98.31%	0.9762	0.9989	97.42%	97.87%	0.9764	0.9994

表6 在FutData25数据集上的消融实验结果

变体模型	强平风险检测				市场动荡风险检测			
	Precision	Recall	F1-score	AUC	Precision	Recall	F1-score	AUC
w/o GAT	92.53%	90.39%	0.9146	0.9488	95.24%	71.43%	0.8163	0.9395%
w/o BiLSTM	85.37%	81.73%	0.8351	0.9219	92.31%	85.71%	0.8889	0.9433%
w/o G	91.56%	90.56%	0.9106	0.9580	88.46%	82.14%	0.8518	0.8946%
Fut-GAT-LSTM	99.73%	96.75%	0.9822	0.9897	96.43%	93.10%	0.9474	0.9897%

中,模型最关注的3种特征依次为大额报撤/频繁报撤、买卖方向和短期成交量。大额报撤/频繁报撤对应异常的流动性扰动和潜在操纵行为;买卖方向反映了市场单边压力的累积效应;而短期成交量的快速变化则直接揭示了市场冲击和波动放大的风险。三者的组合使得模型能够较准确地捕捉潜在的市场失衡信号。




图2 不同特征对两种风险识别的贡献度可视化

在强平风险检测任务中,权重排名靠前的两种特征为买卖方向和持仓限额标志。在期货交易的高杠杆场景下,买卖方向直接决定持仓风险的敞口方向;而持仓限额标志则明确指示交易账户是否已接近监管设定的风险阈值。这两种特征为模型提供了可靠的强平风险预警信号,使其能够准确识别存在潜在的强平风险的异常交易。

对特征贡献度的分析不仅验证了模型在决策过程中聚焦的关键指标与期货市场风控部门高度关注的关键指标高度一致,也为风险判定结论提供了可解释的证据。这一结果表明,Fut-GAT-LSTM模型具备一定的透明性和可信度,能够在实际应用中为监管人员提供重要的参考依据。

3.4.4 案例研究

表7和表8展示了Fut-GAT-LSTM在真实期货交易数据上的检测效果。研究分别选取了FutData23数据集中2023年3月全月(2023年3月1日至2023年3月31日)的数据(共计216 404笔交易)、FutData25数据集中2025年8月11日单日的的数据(共计114 000笔交易),对所提模型在强平风险与市场动荡风险这两类任务上的性能进行了详细分析。

由表7和表8可以看出,Fut-GAT-LSTM在强平风险检测任务和市场动荡风险检测任务中均达到了良好的检测效果,具体如下。

1) 在FutData23数据集上的检测效果:数据集中强平样本共计10 389个,模型准确检测出其中的10 213个,检出率为98.31%,漏检率和误判率分别为1.69%和4.78%;数据集中的市场动荡样

表7 模型在FutData23数据集上的检测情况统计

风险类别	数据集中的异常样本/个	检测出的异常样本/个	检出率	未检测出的异常样本/个	漏检率	误判的异常样本/个	误判率
强平风险	10 389	10 213	98.31%	176	1.69%	497	4.78%
市场动荡风险	414	406	98.07%	8	1.93%	17	4.11%

表8 模型在FutData25数据集上的检测情况统计

风险类别	数据集中的异常样本/个	检测出的异常样本/个	检出率	未检测出的异常样本/个	漏检率	误判的异常样本/个	误判率
强平风险	10 486	10 146	96.76%	340	3.24%	27	0.25%
市场动荡风险	28	26	92.85%	2	7.14%	1	3.57%

本共计414个，模型准确检测出其中的406个，检出率达到98.07%，漏检率和误判率仅为1.93%和4.11%。

2) 在FutData25数据集上的检测效果：数据集中强平样本共计10486个，模型准确检测出其中的10146个，检出率为96.76%，漏检率和误判率分别为3.24%和0.25%；数据集中的市场动荡风险样本共计28个，模型准确检测出其中的26个，检出率达92.85%，漏检率和误判率分别为7.14%和3.57%。

上述结果充分验证了本文所提Fut-GAT-LSTM模型在实际期货市场监管场景中的有效性。

3.4.5 模型泛化性验证

为验证Fut-GAT-LSTM在跨机构、跨时间段及跨市场环境下的适应性和泛化能力，研究人员引入了一组全新的外部测试数据集进行泛化性测试。该数据集来自另一家大型期货公司在2025年7月采集的测试用期货交易数据（已进行脱敏处理），共包含6700笔正常交易和1113笔异常交易。该数据集在时间上与训练数据相隔两年，且覆盖不同的客户群体和交易品种，具备显著的市场分布差异。

在该实验中，使用FutData23数据集训练模型，随后直接在新数据集上进行测试。测试结果见表9。结果显示，尽管面对完全未知的市场环境和客户结构，Fut-GAT-LSTM在两类关键风险检测任务中仍表现出较高的可靠性。在强平风险检测任务中，模型的F1-score达到0.9734，接近在原始FutData-23数据集上取得的0.9762（参见表3）。在市场动荡风险检测任务中，本文模型的F1-score为0.9195，尽管相较于在原始FutData-23数据集上的0.9764有所下降，但仍明显优于多数基线模型在原始数据集上的表现（参见表4）。

表9 泛化场景下的模型性能统计

风险类别	Precision	Recall	F1-score
强平风险	97.45%	97.23%	0.9734
市场动荡风险	85.98%	98.77%	0.9195

上述结果表明，Fut-GAT-LSTM并未依赖特定机构或单一市场环境特征分布，而能够在跨机构、跨市场和跨时间段的条件下保持较强的检

测能力。这说明该模型在风险特征提取和表征方面具有较好的普适性与迁移性，为未来在更广泛的期货监管场景中的应用奠定了基础。

5 结束语

本文提出了一种基于人工智能的期货交易风险评估与预警方法Fut-GAT-LSTM，旨在对日益复杂的期货交易行为及其可能引发的系统性风险进行智能化监管。该方法首先筛选与强平风险及市场动荡风险高度关联的多维度交易特征，并将这些特征数据转换为具有时空特性的动态图序列。然后，通过图注意力网络建模交易内部的空间依赖关系，利用BiLSTM提取交易行为随时间演化的动态特征。最后，基于训练完备的模型计算每个交易节点的风险评分，并结合自适应动态阈值机制实现精准风险预警。实验结果表明，Fut-GAT-LSTM在Precision、Recall、F1-score和AUC值等关键指标上显著优于相关基准方法，在强平风险检测和市场动荡风险检测任务中表现出色。本文方法不仅为期货市场监管提供了新的技术路径，还展现了人工智能技术在金融风险控制领域的广阔应用前景，有助于推动构建更精准、高效、可扩展的智能期货市场监管系统。

参考文献：

- [1] 熊熊, 袁海亮, 张维, 等. 程序化交易及其风险分析[J]. 电子科技大学学报(社科版), 2011, 13(3): 32-39.
Xiong X, Yuan H L, Zhang W, et al. Program trading and its risk analysis[J]. Journal of University of Electronic Science and Technology of China (Social Sciences Edition), 2011, 13(3): 32-39.
- [2] 朱里. 美国高频交易监管机制研究[D]. 上海: 华东政法大学, 2020.
Zhu L. Research on the supervision mechanism of high frequency trading in the united states[D]. Shanghai: East China University of Political Science and Law, 2020.
- [3] 陈汇. 幌骗犯罪论[D]. 上海: 华东政法大学, 2020.
Chen H. Theory of spoofing[D]. Shanghai: East China University of Political Science and Law, 2020.
- [4] 胡乔. 证券投资基金与股市波动性——基于中国的理论与实证[D]. 南昌: 江西财经大学, 2009.
Hu Q. Security investment funds and volatility of stock market: theory and evidence based on china[D]. Nanchang: Jiangxi University of Finance and Economics, 2009.

- [5] 方建珍. 信用风险转移机制研究[D]. 武汉: 武汉理工大学, 2025.
- Fang J Z. A research on credit risk transfer mechanism[D]. Wuhan: Wuhan University of Technology, 2025.
- [6] 王欣, 尹留志, 方兆本. 异常交易行为的甄别研究[J]. 数理统计与管理, 2009, 28(4): 671-677.
- Wang X, Yin L Z, Fang Z B. Research of detecting outlier transaction behavior[J]. Journal of Applied Statistics and Management, 2009, 28(4): 671-677.
- [7] 金升平, 刘钊. 银行异常交易检测方法研究[J]. 武汉金融, 2018, (2): 61-66.
- Jin S P, Liu Z. Research on anomaly detection methods for bank transactions[J]. Wuhan Finance Monthly, 2018(2): 61-66.
- [8] 张启宏. 基于人工智能的金融监管信息系统[J]. 现代计算机(专业版), 2002, (6): 49-51+60.
- Zhang Q H. A Banking supervision information system based on artificial intelligence[J]. Modern Computer (Professional Edition), 2002, (6): 49-51 + 60.
- [9] Liu Z Q, Chen C C, Yang X X, et al. Heterogeneous graph neural networks for malicious account detection[C]//Proceedings of the 27th ACM International Conference on Information and Knowledge Management. New York: ACM, 2018: 2077-2085.
- [10] Quah J T S, Sriganesh M. Real-time credit card fraud detection using computational intelligence[J]. Expert Systems with Applications, 2008, 35(4): 1721-1732.
- [11] Yu W C, Cheng W, Aggarwal C C, et al. NetWalk: a flexible deep embedding approach for anomaly detection in dynamic networks [C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2018: 2672-2681.
- [12] Zheng L, Li Z P, Li J, et al. AddGraph: anomaly detection in dynamic graph using attention-based temporal GCN[C]//Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence. International Joint Conferences on Artificial Intelligence Organization, 2019: 4419-4425.
- [13] Liu Y X, Pan S R, Wang Y G, et al. Anomaly detection in dynamic graphs via transformer[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(12): 12081-12094.
- [14] Michalak K, Korczak J. Graph mining approach to suspicious transaction detection[C]//Proceedings of the 2011 Federated Conference on Computer Science and Information Systems (FedCSIS). Piscataway: IEEE Press, 2011: 69-75.
- [15] Ding K Z, Zhou Q H, Tong H H, et al. Few-shot network anomaly detection via cross-network meta-learning[C]//Proceedings of the Web Conference 2021. New York: ACM, 2021: 2448-2456.
- [16] Aggarwal C C, Zhao Y C, Yu P S. Outlier detection in graph streams[C]//Proceedings of the 2011 IEEE 27th International Conference on Data Engineering. Piscataway: IEEE Press, 2011: 399-409.
- [17] 张建刚. 期货市场自律监管体系比较与借鉴[J]. 武汉理工大学学报(社会科学版), 2005, 18(5): 694-698.
- Zhang J G. International comparison of futures market self-regulation system and its enlightenment to china[J]. Journal of Wuhan University of Technology (Social Sciences Edition), 2005, 18(5): 694-698.
- [18] 尚春梅, 刘继曾. 期货交易的特征与功能[J]. 山西财经大学学报, 1994(5): 54-55, 57.
- Shang C M, Liu J Z. Characteristics and functions of futures trading [J]. Journal of Shanxi University of Finance and Economics, 1994(5): 54-55, 57.
- [19] Zhang Q Y, Zhang Y F, Yao X X, et al. A dynamic attributes-driven graph attention network modeling on behavioral finance for stock prediction[J]. ACM Transactions on Knowledge Discovery from Data, 2024, 18(1): 1-29.
- [20] Siami-Namini S, Tavakoli N, Namin A S. The performance of LSTM and BiLSTM in forecasting time series[C]//Proceedings of the 2019 IEEE International Conference on Big Data (Big Data). Piscataway: IEEE Press, 2020: 3285-3292.
- [21] Zong B, Song Q, Min M R, et al. Deep autoencoding Gaussian mixture model for unsupervised anomaly detection[C]//Proceedings of the International Conference on Learning Representations. 2018.
- [22] Park D, Hoshi Y, Kemp C C. A multimodal anomaly detector for robot-assisted feeding using an LSTM-based variational autoencoder[J]. IEEE Robotics and Automation Letters, 2018, 3(3): 1544-1551.
- [23] Du B W, Sun X X, Ye J C, et al. GAN-based anomaly detection for multivariate time series using polluted training set[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(12): 12208-12219.
- [24] Tuli S, Casale G, Jennings N R. TranAD: deep transformer networks for anomaly detection in multivariate time series data[C]//Proceedings of the VLDB Endowment, 2022, 15(6): 1201-1214.

[作者简介]



常飞 (1989-), 男, 安徽阜阳人, 徽商期货有限责任公司高级工程师, 主要研究方向为信息系统管理、人工智能。



王俊杰 (2002-), 男, 安徽合肥人, 合肥工业大学硕士生, 主要研究方向为机器学习、时间序列异常检测。




胡毅（1986-），男，安徽蚌埠人，徽商期货有限责任公司高级工程师，主要研究方向为期货交易系统、高性能网络架构、信息系统管理。



郭金胜（2005-），男，广东汕头人，合肥工业大学本科生，主要研究方向为机器学习、人工智能安全和概率机器学习。




乔焰（1984-），女，山东聊城人，合肥工业大学副教授，主要研究方向为人工智能、异常检测。



刘奕博（2005-），男，河北邯郸人，合肥工业大学本科生，主要研究方向为深度学习、大数据信息安全。



翁振昊（2004-），男，福建宁德人，合肥工业大学本科生，主要研究方向为人工智能安全、大模型安全。



李萌（1988-），男，安徽合肥人，合肥工业大学教授，主要研究方向为网络安全、隐私保护。