

## 基于博弈动态影响图的股市趋势推理算法

姚宏亮, 尹致远, 杨静, 俞奎

引用本文

姚宏亮, 尹致远, 杨静, 俞奎. 基于博弈动态影响图的股市趋势推理算法[J]. 计算机科学, 2023, 50(11A): 221100039-7.

YAO Hongliang, YIN Zhiyuan, YANG Jing, YU Kui. Stock Market Trend Reasoning Algorithm Based on Game Dynamic Influence Diagram [J]. Computer Science, 2023, 50(11A): 221100039-7.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

### Similar articles recommended (Please use Firefox or IE to view the article)

#### [供需双方均受资金约束的低碳供应链决策研究](#)

Study on Decision-making for a Low-carbon Supply Chain with Capital Constraint on Both Supply and Demand Sides

计算机科学, 2023, 50(11A): 221200130-9. <https://doi.org/10.11896/jsjcx.221200130>

#### [基于动态演化博弈的装备采购模型仿真研究](#)

Simulation of Equipment Procurement Model Based on Dynamic Evolutionary Game

计算机科学, 2023, 50(11A): 220900051-10. <https://doi.org/10.11896/jsjcx.220900051>

#### [基于博弈论的多边缘服务器负载均衡策略](#)

Multi-edge Server Load Balancing Strategy Based on Game Theory

计算机科学, 2023, 50(11A): 221200150-8. <https://doi.org/10.11896/jsjcx.221200150>

#### [基于车流密度的车载边缘计算任务动态卸载策略](#)

Dynamic Unloading Strategy of Vehicle Edge Computing Tasks Based on Traffic Density

计算机科学, 2023, 50(11A): 220900199-7. <https://doi.org/10.11896/jsjcx.220900199>

#### [基于SVD的深度学习模型对抗鲁棒性研究](#)

Study on Adversarial Robustness of Deep Learning Models Based on SVD

计算机科学, 2023, 50(10): 362-368. <https://doi.org/10.11896/jsjcx.220800090>

# 基于博弈动态影响图的股市趋势推理算法

姚宏亮 尹致远 杨静 俞奎

合肥工业大学计算机与信息学院 合肥 230601

**摘要** 股票市场是一个复杂非线性动态系统,具有高度不确定性和多变性,股市趋势预测是数据挖掘领域的一个研究热点。针对基于数据驱动方法所生成的模型鲁棒性差,训练良好的模型不适应实际需要的问题,提出了一种多 Agent 博弈动态影响图模型(Mult-Agent Game Dynamic Influence Diagrams, MAGDIDs)。首先,从博弈的角度引入多方和空方作为股市的行为主体(Agent),提取行为主体的相关特征;然后,利用能量表示博弈主体的力量大小,并对行为主体特征进行量化融合;进而引入博弈策略,构建多 Agent 博弈动态影响图模型,对于股市行为主体的博弈过程进行建模;最后,利用联合树的自动推理技术,预测股市趋势。在实际数据上进行实验,实验结果表明多空博弈趋势预测算法具有良好的性能。

**关键词:** 博弈;多 Agent;鲁棒性;联合树;动态影响图

**中图法分类号** TP181

## Stock Market Trend Reasoning Algorithm Based on Game Dynamic Influence Diagram

YAO Hongliang, YIN Zhiyuan, YANG Jing and YU Kui

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

**Abstract** The stock market is a complex nonlinear dynamic system with high uncertainty and variability. Stock market trend prediction is a research hotspot in the field of data mining. Aiming at the problem that the model based on the data-driven method has poor robustness and the well-trained model does not meet the actual needs, Multi-agent game dynamic influence diagrams (MAGDIDs) is proposed. First of all, from the perspective of the game, the long side and the short side are introduced as the behavior subjects(Agent) of the stock market, and the relevant characteristics of the behavioral subjects are extracted. Next, the power of the game subjects is represented by energy, and the characteristics of the behavioral subjects are quantified and integrated. Then, the game strategy is introduced to build a multi-agent game dynamic influence graph model, and model the game process of the stock market actors. Finally, the automatic reasoning technology of the junction tree is used to predict the stock market trend. Experiments are carried out on actual data, and the results show that the trend prediction algorithm of long-short game has good performance.

**Keywords** Game, Multi-agent, Robustness, Junction tree, Dynamic influence graph

## 1 引言

股票市场是一个复杂的非线性系统,它受基本面、政策面、技术面等因素影响,同时这些因素在股市中表现为买方和卖方力量的动态变化。当前研究者主要从数据驱动的角度研究股市历史数据与未来状态之间的关系,由于股市变化具有不确定性,买卖双方的力量和博弈策略具有时变性,因此股市趋势预测仍然是一个难题。

股市趋势预测是数据挖掘领域的一个研究热点,当前主要研究工作有:文献[1-2]利用股市价格相关数据训练神经网络,通过数据学习模型参数,并利用模型对股市趋势进行预测;文献[3]根据时间序列临近时间点的重要性,提取股市价格指标相关特征,提出了一种时间加权的 LSTM<sup>[4]</sup>模型,该方法具有一定的适用性;文献[5]基于堆叠 LSTM((Stack-Long Short-Term Memory, Stack-LSTM)模型,采用 Adam 算法自

适应地迭代更新权重,提高了股市趋势预测效果;文献[6]使用 MDTW 方法提取特征,利用卷积神经网络学习特征关系,股市趋势预测效果较好,但适应性一般。此后,有研究者<sup>[7-8]</sup>通过引入股市的技术指标以提升提高模型适应性。文献[9]利用贝叶斯网(Bayesian Networks, BNs)对股市相关技术指标进行建模,并利用决策树算法建模混合分类模型,模型预测的适应力有所增强;文献[10]提出一种改进支持向量机(Support Vector Machine, SVM)对股市技术特征进行建模,模型在实际预测中效果较好。

以上研究工作主要是利用股市历史数据拟合网络模型,没有分析股票价格波动的内在原因,学习得到的模型实用价值差。因此本文将针对股市环境易变性,从动态博弈角度出发,研究买卖双方力量变化对于股市趋势的影响,通过多 Agent 建模提升预测算法在实际应用中的鲁棒性。

股市波动是交易主体买卖行为的一种表现形式,是交易

基金项目:国家重点研发计划(2020AAA0106100);国家自然科学基金面上项目(61876206,62176082)

This work was supported by the National Key R & D Program of China(2020AAA0106100) and National Natural Science Foundation of China(61876206,62176082).

通信作者:姚宏亮(dmicyhl@163.com)

双方的博弈结果。博弈是人工智能领域中的对策问题,已有学者将博弈论引入机器学习的方法中<sup>[11]</sup>,如:文献[12]团队作品 AlphaGo,建模了围棋中的二人零和完美信息扩展形势博弈,在围棋对弈中打败了人类顶级选手李世石;文献[13]在二人无限注德州扑克模型中,建模了二人零和非完美信息扩展形势博弈。为了深入研究股市中的博弈过程,本文从数据角度出发,将股市的行为主体抽象成智能体,利用多 Agent 技术对市场的行为主体进行建模。

影响图<sup>[14]</sup>(Influence Diagrams, IDs)模型是处理决策问题的一种重要工具。文献[15]基于影响图模型提出多 Agent 影响图模型(Mult-Agent Influence Diagrams, MAIDs), MAIDs 可以表示 Agent 之间非合作的关系决策,但不能对其他 Agent 进行建模;文献[16]提出交互式动态影响图(I-DIDs),从个体 Agent 视角对其他 Agent 行为进行预测,以建模多 Agent 的动态决策过程;文献[17]结合 MAIDs 和 Agent 之间的动态交互性,提出了一种多 Agent 动态影响图(Mult-agent Dynamic Influence Diagrams, MADIDs),该方法在推理中对环境变化进行预测,将其他 Agent 当作环境的一部分,能够对其他 Agent 建模。综合以上的研究成果,本文在 MA-DIDs 和 I-DIDs 基础上提出多 Agent 博弈动态影响图模型(Mult-Agent Game Dynamic Influence Diagrams, MAG-DIDs),引入多 Agent 博弈策略,增加了 Agent 博弈状态结点,从而建模多 Agent 动态博弈过程。

本文针对股市买卖主体的博弈关系,提取股市与博弈相关的技术指标,建模股市买卖双方的动态博弈过程,以预测股市趋势变化。首先,从能量角度量化股市相关技术指标的多空力量大小;其次,利用贝叶斯网络将技术指标融合成股市买卖能力,用能量结点表示;然后,在动态股市环境中建模股市多空博弈过程;最后,根据股市行情调节博弈状态结点相关参数 $\lambda$ ,利用联合树推理算法预测股市趋势。

本文的主要贡献如下:

(1)用买卖双方的力量表示市场的多空能量,引入博弈状态结点,建模多空 Agent 的动态博弈过程,以提升模型鲁棒性;

(2)理论证明了提出的 MAGDIDs 模型满足结构不变性和纳什均衡原则;

(3)针对不同股市环境,优化博弈状态相关参数 $\lambda$ ,提高了预测算法的适应力。

## 2 股市能量特征

股市是一个复杂的多空动态博弈系统,多空力量的变化是股市波动的内在原因。通常,将股市多方对应买方,将空方对应卖方。多空力量可以用能量进行表示和量化,而股市的能量又和相关技术指标的状态有关。

### 2.1 成交量的能量计算

多空比率净额 VA 是根据多空比率加权修正成交量 V 的结果,VA 可以反映成交量 V 的多空性,设某日股票收盘价 Y 最高价为  $Y_{\max}$ ,最低价为  $Y_{\min}$ ,成交量为 V,则:

$$VA = \frac{(Y - Y_{\min}) - (Y_{\max} - Y)}{Y_{\max} - Y_{\min}} * V \quad (1)$$

成交量 (Volume, V) 是体现股票内在能量的一个主要

要素,用 VA 的变化作为成交量能量的表现。为了平滑成交量的波动性,用 3 日多空比率和 5 日平均多空比率表示成交量的能量,则:

$$E_V = \begin{cases} abs(VA_5 - VA_3) / VA_5, & VA_3 > VA_5 \\ -abs(VA_5 - VA_3) / VA_5, & VA_3 \leq VA_5 \end{cases} \quad (2)$$

### 2.2 移动均线指标的能量计算

移动均线 (Moving Average, MA) 是每日收盘价的移动平均。短均线有 10 日均线 MA10, 20 日均线 MA20; 长均线有 60 日均线 MA60, 120 日均线 MA120。MA $n$  中  $n \in \{10, 20, 60, 120\}$  表示不同时间长度均线名称, 均线值 MA $n_i$  定义为:

$$MA_{n_i} = \frac{endP_{i-n+1} + endP_{i-n+2} + \dots + endP_i}{n} \quad (3)$$

其中,  $endP_i$  表示  $i$  日收盘价, MA $n_i$  表示  $i$  日前  $n$  天收盘价均价。

定义长短均线方向趋势影响因子  $\Delta M^n$  为:

$$\Delta M^n = \begin{cases} \frac{1}{3} \sum_{t=i-2}^i MA_{n_t}, & n \in \{10, 20\} \\ \frac{1}{5} \sum_{t=i-4}^i MA_{n_t}, & n \in \{60, 120\} \end{cases} \quad (4)$$

令  $\Delta E_i^{MA^n} = MA_{n_i} - \Delta M^n$  表示均线与影响因子的偏离程度 ( $\Delta E_i^{MA^{10}}$  表示第  $i$  日 MA10 与影响因子的偏离程度), 则均线能量计算式为:

$$E_{MA} = \begin{cases} |\Delta E_i^{MA^n} * \Delta M^n|, & \Delta E_i^{MA^{10}} > 0 \parallel \Delta E_i^{MA^{20}} > 0 \\ 0, & otherwise \end{cases} \quad (5)$$

$$E_{MA}^c = \begin{cases} |\Delta E_i^{MA^n} * \Delta M^n|, & \Delta E_i^{MA^{60}} > 0 \parallel \Delta E_i^{MA^{120}} > 0 \\ 0, & otherwise \\ -|\Delta E_i^{MA^n} * \Delta M^n|, & \Delta E_i^{MA^{60}} < 0 \parallel \Delta E_i^{MA^{120}} < 0 \end{cases} \quad (6)$$

其中,  $E_{MA}^l$  和  $E_{MA}^c$  分别表示短均线和长线均线能量。

### 2.3 MACD 指标的能量计算

MACD 表示收盘价的短期指数移动均线与长期指数移动均线之间的关系。MACD 由离差 DIF 线、离差值的滑动平均 DEA 线和 MACD 能量柱组成, DIF 线和 DEA 线之间距离为  $M_t = |DIF_t - DEA_t|$ ,  $\Delta MACD_t$  表示  $MACD_t$  和  $MACD_{t-1}$  的差值, 则在  $t$  时刻  $E_{MACD}$  的计算式为:

当  $DIF_t > DEA_t$  时,

$$E_{MACD} = \begin{cases} M_t * \left(\frac{\epsilon - DEA_t}{\epsilon}\right), & \Delta MACD_t \geq 0 \\ (2M_t - 2M_{t-1} + M_{t-2}) * \left(\frac{\epsilon - DEA_t}{\epsilon}\right), & \Delta MACD_t < 0 \end{cases} \quad (7)$$

当  $DIF_t \leq DEA_t$  时,

$$E_{MACD} = \begin{cases} -M_t * \left(\frac{\epsilon - DEA_t}{\epsilon}\right), & \Delta MACD_t < 0 \\ -(2M_t - 2M_{t-1} + M_{t-2}) * \left(\frac{\epsilon - DEA_t}{\epsilon}\right), & \Delta MACD_t \geq 0 \end{cases} \quad (8)$$

其中,  $\epsilon \in [200, 300]$  为调节因子, 一般  $\epsilon$  取 250。调节  $\epsilon$  使  $E_{MACD}$  值服从正态分布, 有利于离散化处理。

### 2.4 收盘价波动能量特征

股市每日收盘价有时序意义, 形成了股票的价格走势。用  $qs_t$  表示当前阶段收盘价和均线的偏离程度:

$$qs_t = \frac{\sum_i \frac{endP_i - MAn_i}{MAn_i}}{t} \times 100\% \quad (9)$$

$t$  表示收盘价波动持续天数; 收盘价波动幅度  $\Delta r$  表示为:

$$\Delta r = \frac{\max(endP_i) - \min(endP_i)}{\max(endP_i)} \times 100\% \quad (10)$$

收盘价的涨跌幅记为  $\Delta P$ , 则收盘价波动能量计算式为:

$$E_p = \Delta r \times qs_t + \frac{\Delta P}{t} \quad (11)$$

## 2.5 股市能量特征融合

利用均值方差对上述特征能量状态进行离散化, 具体的离散方法如下:

$$E^* = \begin{cases} 1, & E_i > E(E_i) + \theta H(E_i) \\ 2, & E(E_i) + \theta H(E_i) \geq E_i \geq E(E_i) - \theta H(E_i) \\ 3, & E_i < E(E_i) - \theta H(E_i) \end{cases} \quad (12)$$

其中,  $i = \{1, 2, 3, 4\}$  分别表示成交量、MACD、股市收盘价波动、长短移动平均线指标能量,  $E(E_i)$  表示特征能量平均值,  $H(E_i)$  为  $E_i$  标准差;  $\theta \in [0, 1]$  为  $H(E_i)$  调节因子, 根据 4 种技术指标离散值的方差来调节  $\theta$ , 使得在大样本下的 4 种指标能量离散结果属于均匀分布;  $E^*$  表示特征能量离散值。

如图 1 所示, 利用贝叶斯网络对相关特征能量进行融合,

则  $t$  时刻股市能量状态  $O_t$  条件概率函数为:

$$P(O_t = E_{P,t}^* | E_{V,t}^*, E_{MA,t}^*, E_{MACD,t}^*, E_{MA,t}^*) \quad (13)$$




图 1 股市能量特征融合

Fig. 1 Fusion of stock market energy characteristics

## 3 多 Agent 博弈动态影响图

多 Agent 博弈动态影响图 (MAGDIDS), 是基于交互式思想对多 Agent 动态影响图的扩展, 其给出了一种股市多空双方的动态博弈结构。

用一个三元组  $MAGDIDS = \langle N, B_t, B_s \rangle$  表示多 Agent 博弈动态影响图, 结构如图 2 所示。其中  $N$  为 Agent 个数, 多空 Agent 分别用  $A_i$  和  $A_j$  表示,  $B_t$  为在  $t$  时刻的影响图,  $B_s$  为转移模型。

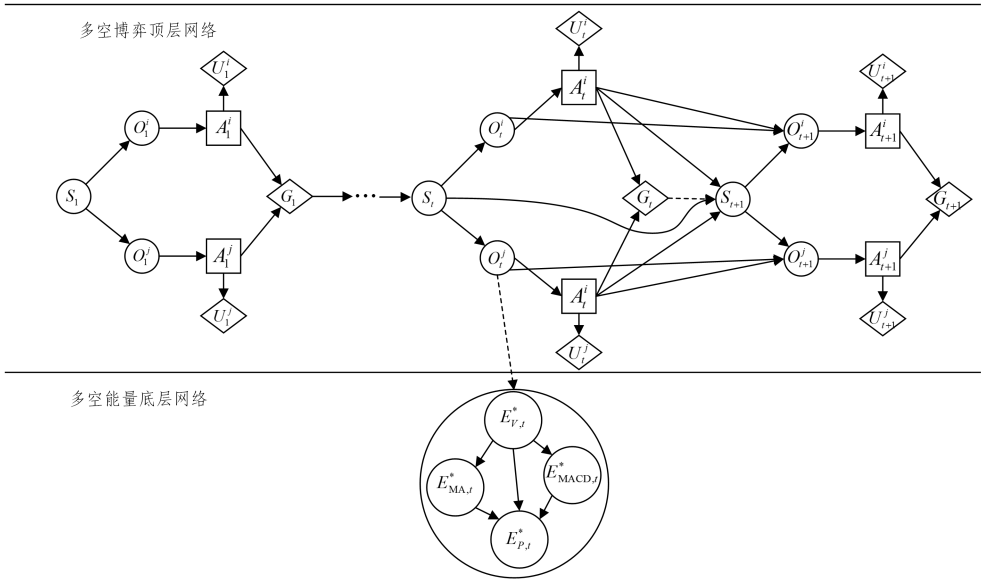


图 2 多 Agent 博弈动态影响图

Fig. 2 Multi-Agent game dynamic influence diagrams

MAGDIDS 结点集  $\langle D, S, O, U, G \rangle$ , 其中  $D$  为决策结点, 状态结点  $S$  表示股市状态, 观测结点  $O$  表示 Agent 对股市能量观测;  $U$  为效用结点,  $G$  为博弈状态结点。在  $t$  时刻 MAGDIDS 状态变量为  $S_t$ , 观测变量集为  $\{O_t^i, O_t^j\}$ , 决策变量集为  $\{D_t^i, D_t^j\}$ , 效用结点集为  $\{U_t^i, U_t^j\}$ , 博弈状态结点为  $G_t$ 。

MAGDIDS 由博弈结构模型、概率模型和效用模型 3 个子模型组成, 具体描述如下。

### 3.1 博弈结构模型

设  $A_i$  在  $t$  时刻博弈策略是一个从状态  $O_t^i$  到策略  $M_t^i$  的映射:  $O_t^i \rightarrow M_t^i$ ,  $A_i$  状态  $O_t^i$  决定了一个策略  $M_t^i$ ; 用  $O_t^{-i}$  表示  $A_i$  推测  $A_j$  在  $t$  时刻可能的状态,  $P(O_t^{-i} | O_t^i)$  表示  $A_i$  在  $O_t^i$  的状态下, 对  $A_j$  状态的概率推断。则在  $t$  时刻  $A_i$  的联合推断概率分布为:

$$P(O_t^{-i}, O_t^i) = \frac{P_i(O_t^{-i}, O_t^i)}{P_i(O_t^i)} = \frac{P_i(O_t^{-i}, O_t^i)}{\sum_{O_t^{-i} \in O_t} P(O_t^{-i}, O_t^i)} \quad (14)$$

其中,  $O_t$  表示  $A_j$  状态集合。

$D_t^i$  表示  $A_i$  行为集,  $\Omega_{Pa(D_t^i)}$  表示  $A_i$  决策结点的父结点的取值空间,  $\Omega_{D_t^i}$  为行为集合。则  $t$  时刻  $A_i$  决策规则  $M_t^i$  是一个从  $D_t^i$  父结点集  $pa(D_t^i)$  到  $D_t^i$  的映射, 如式 (15) 所示:

$$M_t^i: \Omega_{Pa(D_t^i)} \rightarrow \Omega_{D_t^i} \quad (15)$$

其中,  $\Omega_{Pa(D_t^i)}$  表示  $D_t^i$  父结点取值空间,  $\Omega_{D_t^i}$  表示决策变量  $D_t^i$  可能的行为空间。策略模式  $\sigma_t = \{M_t^i, M_t^j\}$  为  $t$  时的每个决策结点分配一个决策规则。  $M_{t,q}^i \in M_t^i$ ,  $q \in \{1, 2, 3\}$  表示  $A_i$  在  $t$  时刻的一个待选策略。

### 3.2 概率模型

MAGDIDS 中概率模型基于 MADIDS<sup>[17]</sup> 加入博弈结构

模型。将决策结点看成随机结点, 给定决策规则  $M_i^t$ , 则  $t$  时刻决策结点  $D_i^t$  的条件概率为:

$$P_{M_i^t}(A_i^t | Pa(D_i^t)) = \begin{cases} 1, & M_i^t(Pa(D_i^t)) = d_i^t \\ 0, & \text{otherwise} \end{cases} \quad (16)$$

其中,  $d_i^t$  是  $A_i$  的一个行为。

给定  $\sigma_t$  的状态变量、观测变量、决策变量, 在  $t$  时刻的联合概率分布为:

$$P_{\sigma_t}(S_t, O_t, A_t) = \prod_{S_i^k \in S_t} P(S_i^k | O_{0:t}, D_{0:t}) \prod_{S_i^k \in S_t} P(O_i^k | S_i^k) \prod_{D_i^k \in D_t} P_{M_i^k}(S_i^k | Pa(D_i^k)) \quad (17)$$

其中,  $k = \{i, j\}$ ,  $D_i^k$  是  $A_k$  的决策变量, 下标  $0:t$  表示从时间 0 到时间  $t$ 。式(17)将博弈结构和决策结点引入到动态贝叶斯网络中。

设 MAGDIDs 满足一阶马尔可夫假设, 则有  $P(S_t | S_{0:(t-1)}, D_{0:(t-1)}) = P(S_t | S_{t-1}, D_{t-1})$  和  $P(O_t | S_{0:t}) = P(O_t | S_t)$ 。给定状态变量的转移概率分布  $P(S_t | S_{t-1}, D_{t-1})$  和观测变量的概率分布  $P(O_t | S_t)$ , 状态变量的概率分布通过转移模型进行传播, 则  $t$  时刻状态变量的先验概率分布:

$$P(S_t | O_{0:(t-1)}, D_{0:(t-1)}) = \sum_{S_{t-1}} P(S_{t-1} | O_{0:(t-2)}, D_{0:(t-2)}) P(S_t | O_{0:(t-1)}, D_{0:(t-1)}) \quad (18)$$

给定  $S_t, O_t, D_t$  和状态变量的条件先验概率分布, 可以得到状态变量的后验概率分布:

$$P(S_t | O_{0:t}, D_{0:t}) = \frac{P(S_t | O_{0:(t-1)}, D_{0:(t-1)}) P(O_t | S_t)}{\sum_{S_t} P(S_t | O_{0:(t-1)}, D_{0:(t-2)}) P(O_t | S_t)} \quad (19)$$

式(18)和式(19)是一个迭代过程。

### 3.3 效用模型

在 MAGDIDs 中, 每个 Agent 有一个效用结点, 表示自身的行为效用。  $A_i$  的效用函数用一个二元组  $\langle U_i^t, G_i \rangle$  表示, 其中  $U_i^t$  表示  $A_i$  在  $t$  时刻的效用结点依赖于  $t$  时刻的  $A_i$  推断概率和效用函数父结点  $Pa(U_i^t)$ ,  $G_i$  为博弈状态结点。

$$U_i^t(M_i^t) = P(O_i^{t-1} | O_i^t) U(Pa(U_i^t)) \quad (20)$$

$A_i$  和  $A_j$  的联合效用表示多空博弈的结果:

$$G_t = U(S_t, D_t) = U_i^t(M_i^t) - U_j^t(M_j^t) \quad (21)$$

给定  $t$  时刻策略模式  $\sigma_t = \{M_i^t, M_j^t\}$ ,  $A_i$  和  $A_j$  的联合期望效用为:

$$EG_t = \sum_{S_t} P_{\sigma_t}(S_t, O_t^k, D_t^k) \sum_{U_i^k \in U_t} P(O_i^{t-k} | O_i^k) U_i^k(Pa(U_i^k)) \quad (22)$$

其中,  $P_{\sigma_t}(S_t, O_t^k, D_t^k)$  为  $A_k$  在  $t$  时刻的概率分布。

### 3.4 博弈状态结点的性质

博弈状态结点表示  $A_i$  和  $A_j$  之间博弈的状态。根据式(22)得到博弈状态结点  $G_t$  的联合效用, 利用 Cooper 变换<sup>[18]</sup> 将  $G_t$  转换为一个 3 状态值集  $\{1, 2, 3\}$ , 其离散值集对应的博弈结果为  $\{\text{多方占优, 多空平衡, 空方占优}\}$ , 该博弈结点条件概率为:

$$P(G=1 | Pa(G)) = \lambda \frac{[u(Pa(G)) + r_2]}{r_1} \quad (23)$$

$$P(G=3 | Pa(G)) = \lambda \frac{[r_3 - u(Pa(G))]}{r_1} \quad (24)$$

$$P(G=2 | Pa(G)) = 1 - P(G=1) - P(G=3) \quad (25)$$

其中,  $r_1 = \max_{Pa(G)}[u(Pa(G))] - \min_{Pa(G)}[u(Pa(G))]$ ,  $r_2 = -\min_{Pa(G)}[u(Pa(G))]$ ,  $r_3 = \max_{Pa(G)}[u(Pa(G))]$ 。  $\lambda \in (0, 1)$  为博弈结果的

调节参数, 在推理中通过调节阈值大小选取最优参数  $\lambda$ , 使模型对于不同股市行情都有较高的准确率。

**定理 1** 给定 MAGDIDs 观测节点状态  $O_i^t$  和  $O_j^t$  以及初始效用函数  $G_0$ , 则  $t > 1$  时  $\sigma_t = \{M_i^t, M_j^t\}$  和  $G_t$  在结构上具有不变性, 且 MAGDIDs 至少存在一个纳什均衡策略组合。

证明结构不变性

(1)  $t=1$  时给定观测结点  $O_i^1, O_j^1$  由式(15)和式(21)可知  $\sigma_1 = \{M_i^1, M_j^1\}$  和  $G_1$  完全依赖于  $B_i$  和  $B_{is}$  的结构, 又因为 MAGDIDs 的  $B_i$  和  $B_{is}$  的结构具有时间不变性, 因而  $t=1$  时  $\sigma_1 = \{M_i^1, M_j^1\}$  和效用模型  $G_1$  也具有结构不变性。当  $t=0$  时,  $B_i$  和  $B_{is}$  的结构不能表示和前一时间点的关系, 而且下一时间点的  $B_i$  和  $B_{is}$  的结构会发生变化, 所以初始效用函数  $G_0$  需要事先给定。

(2)  $t > 1$  时,  $B_i$  和  $B_{is}$  与  $t=1$  时结构相同, 给定状态  $O_i^t$  和  $O_j^t$ ,  $\sigma_t = \{M_i^t, M_j^t\}$  和  $G_t$  完全依赖于  $B_i$  和  $B_{is}$ , 则 MAGDIDs 具有结构不变性。

证明存在纳什均衡

(1)  $A_i$  的策略  $M_i^t$  属于  $O_i^t$  的映射, 其  $t$  时刻的策略模式为  $\sigma_t = \{M_i^t, M_j^t\}$ 。对于  $A_i$  和  $A_j$  任意策略组合  $\{M_{i,q}^t, M_{j,p}^t\}$ ,  $q \in \{1, 2, 3\}$ ,  $p \in \{1, 2, 3\}$ 。根据公式(20)得到的最优行为  $d_i^t$  和  $d_j^t$ , 则称  $M_{i,q}^t$  为  $A_i$  的  $t$  时刻最优策略。  $A_i$  和  $A_j$  的最大期望效用表示为  $U_i^t(M_{i,q}^t), U_j^t(M_{j,p}^t)$ 。

(2) 设  $t$  时刻存在一个策略组合  $\{M_{i,q}^t, M_{j,p}^t\}$  使得  $U_i^t(M_{i,q}^t) \geq U_i^t(M_{i,r}^t), k \neq r \in \{i, j\}$ 。纳什均衡<sup>[19]</sup>表明: 当其他 Agent 保持策略不变时, 没有一个 Agent 会改变自己的策略来提高效用。可知, 给定  $O_i^t$  和  $O_j^t$ , 存在一组策略模式  $\sigma_t = \{M_{i,q}^t, M_{j,p}^t\}$ , 使得  $t$  时 MAGDIDs 博弈满足纳什均衡准则。

## 4 多 Agent 博弈动态影响图联合树推理算法

MAGDIDs 将具有博弈状态的结点  $G_t$  加入到联合树推理算法中, 通过展开技术将动态影响图转换为全贝叶斯网络。

### 4.1 联合树及其相关定义

**定义 1(带弦图)** 带弦图是一个无向图, 图中任意一条长度大于 3 的环都是带弦的。

**定义 2(团)** 团是一个最大无向完备图, 其中最大完备图是指图中每个结点和图中的其他结点都相连。带弦图中的每个不被其他完备子图包含的完备子图对应一个团。

**定义 3(接口)** 在 DBNs 中, 接口连接两个相邻时间片  $t$  和时间片  $t+1$ , 包含时间片  $t$  内所有指向时间片  $t+1$  发出弧的节点集合(见图 3), 时间片  $t$  的接口可表示为  $I_t$ 。




图 3 MAGDIDs 的接口(电子版为彩图)

Fig. 3 Interface of MAGDIDs

图 3 中红色节点表示 MAGDIDs 接口节点, 其中  $I_t = \{S_t, D_i^t, D_j^t, G_t\}$ 。

**定义 4(联合树)** 一个联合树定义为一个二元组  $JT=(C, Z)$ , 其中  $C$  是团结点集合,  $Z$  是割集,  $C$  中的两个团通过  $Z$

中的团结点相连。对于任意相邻团  $C_i$  和  $C_j, C_i, C_j \in C, z(i, j)$  为  $C_i$  和  $C_j$  之间的一个分割团,  $z(i, j)$  属于  $Z$ 。

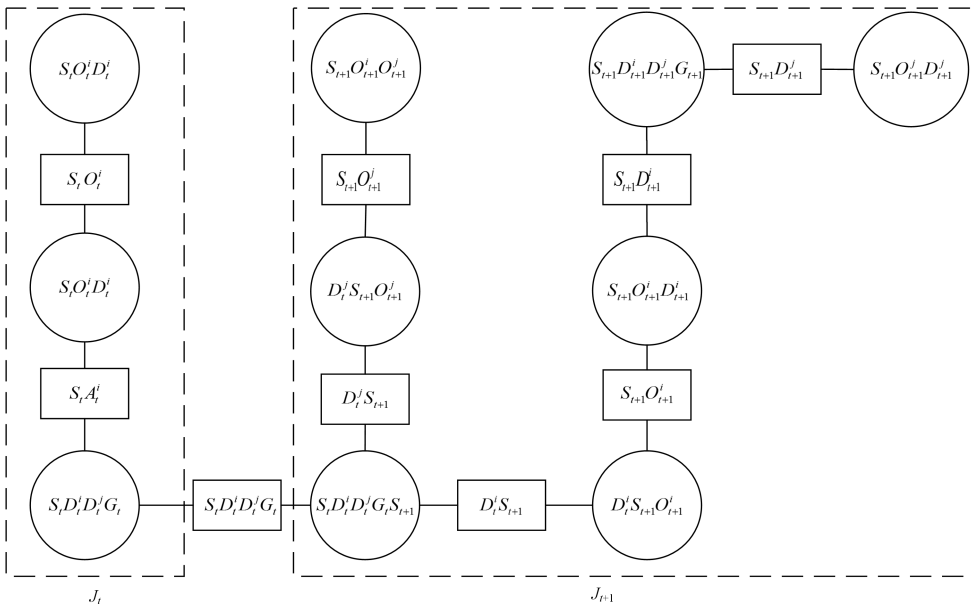


图 4 联合树

Fig. 4 Junction tree

**定义 5(势)** 势是一个非负的实函数, 它将变量或变量集的概率分布映射到一个与每个实例相对应的非负实函数, 用  $\varphi$  表示。

#### 4.2 构建 1.5 时间片联合树

展开网络中第  $t$  和  $t+1$  两个相邻时间片网络, 从时间片  $t$  消除所有非接口结点和与之连接的边, 再和时间片  $t+1$  进行组合, 得到 1.5 时间片 DBN; 对 1.5 时间片 DBN 进行正规化、三角化操作, 生成联合树  $JT_{t+1}$ , 如图 3 所示。对于 MAGDIDs 任意两个相邻时间片  $t$  和  $t+1$ , 接口  $I_t$  可以将这两个时间片进行隔离。将 MAGDIDs 中  $t$  和  $t+1$  时间片通过接口粘合得到如图 4 所示的联合树。其中接口  $I_t = \{S_t, D_t^i, D_t^j, G_t\}$ 。

以接口  $I_t$  和  $I_{t+1}$  为分割团, 将所有时间片的联合树粘合起来生成 MAGDIDs 完整联合树。如图 5 所示, 每个联合树中含有  $I_t$  和  $I_{t+1}$  ( $JT_t$  为初始时间片仅包含  $I_1$ ), 其中  $I_t$  表示  $JT_t$  和  $JT_{t+1}$  的接口,  $N_t$  表示非接口结点,  $B_t$  为包含接口  $I_t$  的团,  $C_t$  为包含接口  $I_{t+1}$  的团。




图 5 通过接口粘合相邻联合树示意图

Fig. 5 Schematic diagram of bonding adjacent junction trees through interface

#### 4.3 MAGDIDs 推理预测算法描述

MAGDIDs 推理预测算法的描述如算法 1 所示。

##### 算法 1 MAGDIDs

输入: A 股市场原始股票数据集, 参数  $\lambda$

输出: 股市趋势  $S_{t+1}$

1. 从 A 股市场提取目标股票 SD 相关数据集, 将数据集划分为训练

数据集和测试数据集。

2. 计算目标股票 SD 在  $t$  时间片的技术指标能量  $E_V, E_{MACD}, E_P, E_{MA}$ , 利用均值方差离散 4 种技术指标能量得到  $E_V^*, E_{MACD}^*, E_P^*, E_{MA}^*$ 。

3. 利用贝叶斯网络将 4 种技术指标融合为股市能量结点  $O_t$ 。

4. 将  $t$  时刻  $O_t, O_t^i$  和状态结点  $S_t$  以及博弈结果阈值  $\lambda$  作为 MAGDIDs 模型输入。

5. 从  $t=1$  开始, 对顶层网络构建联合树  $JT_t$ , 初始化  $JT_t$  中所有的团以及分割团中的条件概率表。令  $I_t = \{S_t, D_t^i, D_t^j, G_t\}$  的团,  $C_t$  为包含  $I_{t+1} = \{S_{t+1}, D_{t+1}^i, D_{t+1}^j, G_{t+1}\}$  的团。

6. 在  $C_{t-1}$  中通过边缘化操作得到  $I_{t-1}$  的概率分布, 将  $I_t$  的概率分布作为先验分布  $\sum_{C_{t-1} \setminus I_{t-1}} C_{t-1} = P(I_{t-1} | X_{1:t-1})$  (其中  $X_{1:t-1}$  表示有效证据), 并将先验概率分布的乘积作为  $B_t$  的概率分布, 在  $JT_t$  以  $C_t$  作为根结点收集证据。

7.  $JT_{t+1}$  向  $JT_t$  传播概率, 实现对  $JT_t$  概率分布的更新, 边缘化  $B_{t+1}$  得到  $I_t$  的联合概率分布  $\sum_{B_{t+1} \setminus I_t} B_{t+1} = P(I_t | X_{1:t})$ ,  $JT_t$  吸收  $B_{t+1}$  的概率

分布  $C_t$  的条件概率表, 即  $\phi_B^* = \phi_B \times \frac{\sum_{B/C} \phi_C}{\sum_{B/C} \phi_B}$ 。在  $JT_t$  中以  $C_t$  为根结点, 进行分发证据的操作。

8.  $t=t+1$ , 若  $t < T$  则返回步骤 6。

9. 对于预测目标结点  $S_{t+1}$  所在的分割团, 给定证据  $X$  后求得  $S_{t+1}$  的后验概率  $P(S_{t+1} | X)$ 。

## 5 实验结果及分析

实验选取沪深 A 股 2015 年 1 月 1 日至 2020 年 12 月 31 日, 大约 11000 份行业板块数据。其中, 2015-01-01 至 2018-12-31 之间的数据为训练集, 占 80%; 2019-01-01 至 2020-12-31 之间的数据为测试集, 占 20%。设涨幅大于 5% 为上涨, 涨跌幅在 -5% 至 5% 为横盘, 当跌幅大于 5% 为下跌。

### 5.1 评价标准

为验证算法的有效性, 用准确度、召回率、F1 综合指标作为评价指标, 具体公式如下:

$$P = \frac{TP}{TP + FP} \tag{26}$$

$$R = \frac{TP}{TP + FN} \tag{27}$$

$$F_1 = \frac{2 \times P \times R}{P + R} \tag{28}$$

其中,  $TP$  表示预测为真的正样本,  $TN$  表示预测为负的正样本,  $FP$  表示预测为正的负样本,  $FN$  表示预测为负的正样本。

MAGDIDs 建模股市多空博弈过程, 针对不同股市行情调节参数  $\lambda$  的值, 优化  $\lambda$  参数。LSTM 和 Stack-LSTM 算法使用股市收盘价、开盘价、成交量、均线数据作为输入。RTS-CNN 算法的输入与 MADIDs 相同, 针对量化后技术指标进行实验。

### 5.2 MAGDIDs 最优参数 $\lambda$ 选择

采用二分法选取  $\lambda \in (0, 1)$  在 2019 年 1 月 1 日至 2020 年 12 月 31 日时间段内的 2000 条测试数据上进行实验, 根据测试结果分析选取不同参数  $\lambda$  对震荡行情、上涨、下跌行情下 MAGDIDs 预测精确率的影响, 结果如图 6—图 8 所示。




图 6 上涨行情下  $\lambda$  参数折线图

Fig. 6 Line chart of  $\lambda$  parameter in bull market




图 7 震荡行情下  $\lambda$  参数折线图

Fig. 7 Line chart of  $\lambda$  parameter in fluctuating market




图 8 下跌行情下  $\lambda$  参数折线图

Fig. 8 Line chart of  $\lambda$  parameter in bear market

实验结果表明在不同行情下 MAGDIDs 算法的预测精确率随着  $\lambda$  增大逐渐增大, 在上涨、震荡、下跌行情下, 当  $\lambda$  达到 0.625, 0.75, 0.625 时算法精确率达到最大值分别为 65.48%, 62.12%, 63.48%。通过二分法调参实验, 得到不同行情下 MAGDIDs 最优参数  $\lambda$  分别为 0.625, 0.75, 0.625。

### 5.3 实验结果对比分析

图 9 为 LSTM, Stack-LSTM, RTS-CNN, MADIDs,

MAGDIDs( $\lambda = 0.75$ ) 算法在 2019-09-01 至 2020-12-31 时间段内的 2000 个样本下, 震荡行情中 40 个预测结果对比。算法预测值与实际值不吻合的预测点依次为 18, 11, 14, 13, 9, 具体实验结果对比如表 1、表 2 所列。




图 9 5 种算法结果对比

Fig. 9 Results Comparison of five algorithms

表 1 1000 条数据实验结果对比

Table 1 Algorithm comparison based on 1000 real samples (单位: %)

Algorithm	Status	Accuracy	Recall	F1
LSTM	Upward	55.15	56.45	55.79
	turbulence	54.37	58.24	56.24
	Downward	56.37	51.02	53.56
Stack-LSTM	Upward	56.06	53.45	54.72
	turbulence	55.37	46.02	50.26
RTS-CNN	Downward	55.42	58.28	58.28
	Upward	57.43	60.63	58.99
	turbulence	55.14	58.36	49.36
MADIDs	Downward	58.21	59.28	58.74
	Upward	57.09	59.52	58.28
MAGDIDs	turbulence	57.26	58.37	57.80
	Downward	59.14	56.07	57.56
MAGDIDs	Upward	65.27	61.75	63.46
	turbulence	61.87	68.76	65.13
	Downward	63.31	62.48	62.90

表 2 2000 条数据实验结果对比

Table 2 Algorithm comparison based on 2000 real samples (单位: %)

Algorithm	Status	Accuracy	Recall	F1
LSTM	Upward	54.62	50.72	52.60
	turbulence	53.37	52.16	54.18
	Downward	55.40	53.47	54.18
Stack-LSTM	Upward	56.09	56.25	56.16
	turbulence	53.37	53.05	53.21
RTS-CNN	Downward	56.52	63.28	59.71
	Upward	56.14	61.38	56.96
	turbulence	55.29	61.38	58.17
MADIDs	Downward	58.17	64.28	61.07
	Upward	56.82	58.49	57.64
MAGDIDs	turbulence	56.76	56.37	56.56
	Downward	58.93	57.07	57.99
	Upward	65.48	60.87	63.10
MAGDIDs	turbulence	62.12	63.76	62.93
	Downward	63.48	64.36	63.41

表 1 列出了 2019 年 1 月 1 日至 2019 年 8 月 31 日时间段的 1000 条测试数据对比结果, 表 2 为 2019 年 3 月 1 日至 2019 年 5 月 1 日的 2000 条测试数据的对比结果, MAGDIDs 算法  $\lambda$  取值分别为 0.625, 0.75, 0.625。

由表 1 可知, 当测试数据集为 2019 年 1 月 1 日至 2019 年 8 月 31 日时间段的 1000 条数据时, 股市趋势为上涨、横盘、下跌, MADIDs 算法的准确率和召回率都明显优于 LSTM, Stack-LSTM, RTS-CNN 算法。实验结果表明, 利用基本的历史数据拟合模型, 算法鲁棒性不高; MAGDIDs 精确率分别为

65.27%,61.87%,63.31%明显高于MADIDs算法,因而股市动态博弈建模方法的预测效果良好。

由表2可知,当测试集数据为2019年3月1日至2019年5月1日时间段的2000个测试数据时,LSTM算法、Stack-LSTM算法精确度、召回率和F1指标均明显下降,RTS-CNN在下跌行情下算法准确率也明显下降;MADIDs算法波动较小,其中精确度、召回率都有小幅度下降;然而,MAGDIDs在2000条测试数据下仍然具有良好的效果。说明MAGDIDs模型具有稳定性高和适应性强的优势。

由表1和表2可知,多数算法在上涨和下跌行情下准确率和召回率明显高于股市震荡下算法的精确率和召回率。在股市震荡行情下,股市技术指标和价格趋势噪声较大,股市趋势和技术指标存在较强背离,影响预测效果。MAGDIDs算法建模动态博弈,并对博弈参数 $\lambda$ 优化调节,适用于复杂行情下的趋势预测。

**结束语** 多Agent动态影响图是建模动态环境下系统演化的一种有力工具。针对股市的动态多变性导致学习的模型难以适应新的环境这一问题,从多空博弈的角度入手,研究多空Agent的博弈行为对市场趋势的影响。将博弈策略引入到MADIDs中,提出了一种博弈MADIDs模型;根据动态博弈的结果,利用联合树算法对股市趋势进行动态预测,以提升预测模型在实际应用中的鲁棒性。由于Agent行为存在情绪性,导致博弈的结果存在非理性的一面,将来可以进一步从情绪角度研究多空Agent的博弈机理。

## 参考文献

- [1] ZHANG D H, LOU S. The application research of neural network and BP algorithm in stock price pattern classification and prediction[J]. Future Generation Computer Systems, 2021, 115: 872-879.
- [2] DE OLIVERIRA F A, NOBRE C N, ZARATE L E. Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index-Case study of PETR4, Petrobras, Brazil [J]. Expert Systems with Applications, 2013, 40(18): 7596-7606.
- [3] ZHAO Z Y, RAO R N, TU S X, et al. Time-weighted LSTM model with redefined labeling for stock trend prediction[C]// 2017 IEEE 29th International Conference on Tools with Artificial Intelligence (ICTAI). IEEE, 2017: 1210-1217.
- [4] SELVIN S, VINAYAKAKUMAR R, GOPALAKRISHNAN E A, et al. Stock price prediction using LSTM, RNN and CNN-sliding window model[C]// 2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI). IEEE, 2017: 1643-1647.
- [5] OJO S O, OWOLAWI P, MPHABLELE M, et al. Stock Market Behaviour Prediction using Stacked LSTM Networks[C]// 2019 International Multidisciplinary Information Technology and Engineering Conference (IMITEC). IEEE, 2020: 1-5.
- [6] HOOI B, LIU S, SMALAGIC A, et al. BEATLEX: Summarizing and Forecasting Time Series with Patterns[C]// Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Cham: Springer, 2017: 3-19.
- [7] QIN X Y, PENG Q K. Stock turning point recognition using multiple model algorithm with multiple types of features[C]// Proceedings of the 10th World Congress on Intelligent Control and Automation. IEEE, 2012: 4020-4025.
- [8] CHANDRIKKA P V, VISALAKKSHMI K, SRINIVASAN K S. Application of Hidden Markov Models in Stock Trading [C]// 2020 6th International Conference on Advanced Computing and Communication Systems (ICACCS). IEEE, 2020: 1144-1147.
- [9] CHENG S H. A Hybrid Predicting Stock Return Model Based on Bayesian Network and Decision Tree[C]// 2014 6th International Conference on Industrial. Springer International Publishing, 2014: 218-227.
- [10] LIU Z X, DANG Z Y, YU J. Stock Price Prediction Model Based on RBF-SVM Algorithm[C]// 2020 International Conference on Computer Engineering and Intelligent Control (ICCEIC). IEEE, 2020: 124-127.
- [11] HERNANDEZ-LEAL P, KAISERS M, BAARSLAG T, et al. A Survey of Learning in Multiagent Environments: Dealing with Non-Stationarity[J]. arXiv: 1707.09183, 2017.
- [12] SILVER D, HUANG A, MADDISON C J, et al. Mastering the game of Go with deep neural networks and tree search[J]. Nature, 2016, 529(7587): 484-489.
- [13] MORAVCIK M, SCHMID M, BURCH N, et al. DeepStack: Expert-level artificial intelligence in heads-up no-limit poker[J]. Science, 2017, 356(6337): 508-513.
- [14] HOWARD R A, MATHESON J E. Influence Diagrams [J]. Principles & Applications of Decision Analysis, 2005, 2(3): 127-143.
- [15] KOLLER D, MILCH B. Multi-agent influence diagrams for representing and solving games[J]. Games and Economic Behavior, 2003, 45(1): 181-221.
- [16] DOSHI P, ZENG Y, CHEN Q. Graphical models for interactive POMDPs: representation and solutions[J]. Autonomous Agents and Multi-Agent Systems, 2009, 18(3): 376-416.
- [17] YAO H L, WANG H, ZHANG Y S, et al. Research on multi-agent dynamic influence diagrams and its approximate inference algorithm[J]. Chinese Journal of Computers, 2008, 31(2): 236-244.
- [18] COOPER G F. A Method for Using Belief Networks as Influence Diagrams[C]// 4th Workshop on Uncertainty in Artificial Intelligence. 2013: 55-63.
- [19] ZHOU L, YIN Q Y, HUANG K Q. Game-Theoretic Learning in Human-Computer Gaming[J]. Chinese Journal of Computers, 2022, 45(9): 1859-1876.



**YAO Hongliang**, born in 1970, Ph. D., associate professor. His main research interests include machine learning and data mining.