

双层动态金融网络中心性与资产配置效率

——基于MT-HITS算法的实证研究

胡明倩, 王花蝶, 杨斯淇, 黄 羿*

吉首大学数学与统计学院, 湖南 吉首

收稿日期: 2026年7月24日; 录用日期: 2026年8月15日; 发布日期: 2026年8月25日

摘 要

金融市场中资产间的关联不仅包含线性风险传导特征, 还包含复杂的非线性信息交互机制, 但传统基于相关系数构建的金融网络已难以全面刻画市场真实的运行规律。本文基于沪深300成分股的日交易数据, 采用滚动窗口法构建融合Granger线性因果关系与Transfer Entropy非线性信息流的双层动态金融网络, 并使用六阶张量融合时间维度与层间关系, 再用MT-HITS算法计算出股票网络的Hub中心性与Authority中心性, 并在此基础上, 构建网络中心性选股策略, 并结合CVaR模型进行投资组合优化。结果表明: 金融市场具有明显的动态变化特征, 使用低Authority中心性策略的投资效果显著优于基准策略, 即可说明网络核心股票往往承担较高的系统性风险, 而处于网络边缘的股票则具有更优的风险收益特征。

关键词

金融网络, CVaR模型, 投资组合优化

Two-Layer Dynamic Financial Network Centrality and Asset Allocation Efficiency

—An Empirical Study Based on the MT-HITS Algorithm

Mingqian Hu, Huadie Wang, Siqi Yang, Yi Huang*

School of Mathematics and Statistics, Jishou University, Jishou Hunan

Received: July 24, 2026; accepted: August 15, 2026; published: August 25, 2026

Abstract

The interconnections among assets in financial markets encompass both linear risk transmission

*通讯作者。

文章引用: 胡明倩, 王花蝶, 杨斯淇, 黄羿. 双层动态金融网络中心性与资产配置效率[J]. 统计学与应用, 2026, 15(8): 266-278. DOI: 10.12677/sa.2026.158196

characteristics and complex nonlinear information interaction mechanisms. However, traditional financial networks constructed based on correlation coefficients are inadequate for fully capturing the true operational patterns of the market. This paper utilizes daily trading data of CSI 300 constituent stocks and adopts a rolling window approach to construct a two-layer dynamic financial network that integrates Granger causality for linear risk transmission and Transfer Entropy for nonlinear information flow. Furthermore, a sixth-order tensor is employed to integrate the temporal dimension with inter-layer relationships, and the MT-HITS algorithm is applied to compute the Hub centrality and Authority centrality of stocks within the network. On this basis, a stock selection strategy based on network centrality is developed and combined with the CVaR model for portfolio optimization. The results show that the financial market exhibits significant dynamic evolution characteristics. The investment strategy based on low Authority centrality significantly outperforms the benchmark strategy, indicating that core stocks in the network tend to bear higher systemic risk, while stocks at the network periphery demonstrate superior risk-return profiles.

Keywords

Financial Networks, CVaR Model, Portfolio Optimization

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着金融市场复杂性不断增强,资产之间的关联关系已不再局限于传统意义上的简单线性相关性,而是呈现出明显的网络化和动态化特征。传统的均值-方差模型通过资产收益率的协方差矩阵刻画风险特征,为现代的投资组合优化理论奠定了基础[1]。然而,该模型以收益率方差作为风险测度,隐含着收益服从正态分布的假设,在极端市场中容易低估尾部风险。为此,条件风险价值(Conditional Value-at-Risk, CVaR)模型被提出,该模型通过关注损失分布尾部区域,能够量化传统风险价值无法涵盖的各类风险因素,目前已成为投资组合优化中风险管理的重要工具[2]。

随着金融市场的关联性逐渐增强,越来越多的学者发现资产间的相互作用已经难以通过传统的协方差矩阵来描述,开始使用复杂网络理论分析法研究金融市场的结构。从20世纪末提出的小世界网络[3]、无标度网络[4]以及特征向量中心性[5]等这些经典模型的提出以来,复杂网络理论已经从最基础的理论探索逐步融入到各个现实领域,现已成为解析复杂系统规律的核心工具。Mantegna最早使用最小生成树网络来研究金融市场的网络结构,开启了金融网络研究的新方向[6]。之后,学者们进一步从理论上证明了在Markowitz理论框架下,使用金融市场网络中资产的中心性与其最优权重之间存在负相关关系[7]。更进一步地,牛晓健和梁张诚构建最小生成树网络,证明股票市场具有复杂网络特征,并且这些特征不会随时间的推移而发生改变[8]。为了突破传统的投资组合优化静态网络的假设与互相关矩阵噪声干扰的双重局限,Li等运用网络滤波方法和边缘性度量指标,创新性地提出了动态网络拓扑、资产筛选、组合优化的完整路线,为投资策略提供了理论的严谨性与实践可操作性的新方法[9]。

金融网络的结构特征与市场风险状态之间紧密关联,网络拓扑结构的动态变化包含着重要的投资信息,随着研究的深入,学者们意识到单一的网络难以全面的刻画复杂的金融关联网络。由此,多层网络与时序网络逐渐成为复杂网络研究的重要方向。Kivela等系统地构建了多层网络理论[10],Boccaletti对由组成成分之间各种关系(层)构成的图的结构和动态组织进行了全面的综述,并进一步指出多层网络能

够更真实地刻画出现实中复杂系统的多维关联关系[11]。在金融领域, Billio 等基于主成分分析和 Granger 因果检验来构建关系网络[12], Diebold 和 Yilmaz 提出了几种基于方差分解构建的连通性度量方法, 并论证了这些方法能够深刻地衡量金融资产收益和波动率之间的连通性[13]。与此同时, 对于多层网络中节点重要性的测度问题, Arrigo 和 Tudisco 为时序有向多层网络引入了一种新的排序模型, 将 HITS 算法的相互强化逻辑扩展至该框架, 并由此提出 MD-HITS 模型[14]。Lv 等进一步的利用六阶张量统一表示多层时序网络, 提出多层时序超链接诱导主题搜索(Multi-layer Temporal Hyperlink-Induced Topic Search, MT-HITS)中心性, 该中心性测度同时考虑了多层时序网络的时间依赖性和多重相互作用, 更好地描述了网络的拓扑结构, 为动态金融网络的分析提供了新的研究工具[15]。王纲金等构建多层关联网络, 实证发现股票权重与节点中心度呈负相关关系, 而低中心度策略的等权重组合表现最优[16]。赵霞等将时序网络与向量自回归模型结合, 进一步地深化了对动态关联结构的刻画[17]。杨剑楠等结合多层耦合网络分析法, 以节点邻居的拓扑重叠系数来度量层间关系, 证实了层间相似性的度量对于时序网络的节点重要性度量具有十分重要的意义[18]。刘超等将多层时序网络中心性与投资组合优化理论相结合, 提出了全局最小网络风险模型, 丰富了投资者的投资策略, 但其对时间维度上的持续影响与市场记忆效应的刻画仍存在完善空间[19]。

本文的主要贡献体现在以下三个方面。一是构建融合 Granger 线性因果关系与 Transfer Entropy 非线性信息流的双层动态金融网络, 能更全面地刻画股票间复杂的关联结构; 二是利用六阶张量整合时间维度与层间的关系, 采用 MT-HITS 算法计算双层时序网络的中心性, 提升网络结构信息的刻画能力; 三是将网络中心性与 CVaR 风险优化模型相结合, 为基于复杂网络的动态投资组合构建提供了新的实证依据。

本文其余部分结构安排如下: 第 2 节介绍相关方法, 第 3 节是实证分析, 具体包含数据预处理、网络拓扑结构分析与稳健性检验部分。第 4 节给出研究结论并提出相关建议。

2. 方法

2.1. 双层金融网络模型

为了能够捕捉到股票间的不同维度的信息传递关系, 本文构建了两层有向加权网络: 第一层基于格兰杰因果度量的线性预测关系, 第二层基于传递熵度量的非线性信息流动关系, 两层网络共享相同的节点集(股票), 并各自保留有向边的强度。

1) 格兰杰因果网络

$$r_j(t) = \alpha_0 + \sum_{k=1}^p \alpha_k r_j(t-k) + \sum_{k=1}^p \beta_k r_i(t-k) + \varepsilon_t, \quad (1)$$

其中, p 为滞后阶数, 根据 AIC 信息准则, 本文取 $p=2$, ε_t 为随机误差项, 当 $\beta_k=0$ 时, 该模型为受限模型, 当 $\beta_k \neq 0$ 时, 模型为非受限模型。

若股票 i 的历史收益率信息能够显著提高对股票 j 未来收益率的预测能力, 则认为股票 i 对股票 j 存在 Granger 因果关系, 即建立从节点 i 指向节点 j 的有向边。为了衡量因果关系强度, 本文进一步采用 F 统计量作为边权, 其定义为

$$F = \frac{(RSS_r - RSS_u)/p}{RSS_u/(T-2p-1)} \sim F(p, T-2p-1), \quad (2)$$

其中, RSS_r 为受限模型的残差平方和, RSS_u 为非受限模型的残差平方和, T 为样本长度, p 为滞后阶数, 当 F 大于临界值, 则拒绝原假设 H_0 , 认为存在格兰杰因果关系, 即 x 是 y 的格兰杰原因, F 统计量越大,

表明 x 对 y 的预测能力越强。当 Granger 因果检验通过显著性检验时, 建立股票 i 到股票 j 的有向边, 并定义边权为 $w_{ij}^{(G)} = F_{ij}$, 由此得到格兰杰因果网络为 $G^{(G)} = (V, E^{(G)})$, V 表示股票节点集合, $E^{(G)}$ 表示格兰杰因果边集合。该网络能够反映金融市场中的线性风险传播结构, 即某些股票价格波动对其他股票未来波动的线性影响关系。

2) 传递熵网络

传递熵是一种基于信息论的信息流测度, 用于衡量一个时间序列对另一个时间序列的未来状态所提供的额外信息量。对于任意两个收益率序列 X 与 Y , 从 X 到 Y 的传递熵定义为

$$TE_{X \rightarrow Y} = \sum p(y_{t+1}, y_t, x_t) \log \frac{p(y_{t+1} | y_t, x_t)}{p(y_{t+1} | y_t)}, \quad (3)$$

其中, $p(y_{t+1}, y_t, x_t)$ 表示联合概率分布, 分子表示在已知 X 和 Y 的历史信息条件下 Y 未来状态的条件概率, 分母表示仅已知 Y 自身的历史信息时的条件概率。

传递熵网络衡量的是加入 X 的历史信息后, 对 Y 未来状态预测的不确定性减少程度。因此, 当传递熵值越大时, 说明 X 对 Y 的未来状态提供了更多的额外信息, 即两者之间存在更强的非线性信息传递关系。若股票 i 对股票 j 的传递熵显著, 则建立从节点 i 指向节点 j 的有向边, 并定义边权为 $w_{ij}^{TE} = TE_{ij}$, 由此得到传递熵网络为 $G^{(TE)} = (V, E^{(TE)})$ 。

3) 双层金融网络

记格兰杰邻接矩阵为 $A_G^{(t)}$, 传递熵层邻接矩阵为 $A_T^{(t)}$ 。为统一标记, 可令 $\alpha=1$ 为格兰杰层, $\alpha=2$ 表示传递熵层, 则有 $A_\alpha^{(t)} \in \mathbb{R}^{N \times N}$ 。进一步地, 为降低网络噪声并增强网络的稀疏性, 依据文献[20]本文对网络的边进行 Top-10% 的筛选策略, 即仅保留每层网络中权重排名前 10% 的边, 从而构建出较为稳定的稀疏有向网络结构。设网络邻接矩阵为 $A = [a_{ij}]$, 则有

$$a_{ij} = \begin{cases} w_{ij}, w_{ij} \in \text{Top}K \\ 0, \text{其他} \end{cases} \quad (4)$$

本文基于张量方法表示双层金融网络, 双层金融网络定义为 $G = \{G^{(G)}, G^{(TE)}\}$, $G^{(G)}$ 表示格兰杰线性因果风险传递网络层, $G^{(TE)}$ 表示传递熵非线性信息传递网络层。使用六阶张量可表示为 $\mathbb{T} \in \mathbb{R}^{N \times N \times L \times L \times n_T \times n_T}$, N 为节点数(股票), L 为网络层数, n_T 为时间窗口数, 其元素 $\mathbb{T}_{t, \tau, \alpha, \beta, i, j}$ 表示从 τ 窗口 β 层节点 j 指向 t 窗口 α 层节点 i 的超边权重, 表达式为

$$\mathbb{T}_{t, \tau, \alpha, \beta, i, j} = \begin{cases} (A_\alpha^{(t)})_{i, j}, & \text{如果 } t = \tau \text{ 且 } \alpha = \beta \\ S_\alpha^{t, \tau}, & \text{如果 } t \neq \tau \text{ 且 } \alpha = \beta, i = j \\ 0, & \text{其他} \end{cases} \quad (5)$$

其中, $t = \tau$, $\alpha = \beta$ 表示同窗口、同层, 张量元素直接取自原始网络的邻接矩阵, 保留股票间的真实信息传导。 $t \neq \tau$, $\alpha = \beta$ 且 $i = j$ 表示不同窗口、同层的情况下, 仅同一节点自身在不同时刻存在耦合(自环), 权重取该层对时间窗口的 PageRank 相似度 $S_\alpha^{t, \tau}$, 不同节点之间无跨期连接。其计算方法如下。

首先对每个窗口 t 的每一层 α , 计算其行随机转移矩阵 $M_\alpha^{(t)} \in \mathbb{R}^{N \times N}$ 为

$$(M_\alpha^{(t)})_{ji} = \frac{(A_\alpha^{(t)})_{ij}}{\sum_{k=1}^N (A_\alpha^{(t)})_{ik}}, \text{若 } \sum_{k=1}^N (A_\alpha^{(t)})_{ik} > 0. \quad (6)$$

如果节点 i 的出度为 0, 则令 $(\mathbf{M}_\alpha^{(t)})_{ji} = \frac{1}{N}$ 。则 PageRank 向量 $PR_\alpha^{(t)} \in \mathbb{R}^N$ 满足

$$PR_\alpha^{(t)} = \frac{1-d}{N} \mathbf{1} + d (\mathbf{M}_\alpha^{(t)})^T PR_\alpha^{(t)}, \quad (7)$$

其中, d 为阻尼系数, 通常取 0.85, 采用幂迭代法求解至收敛。

然后再定义同一层 α 在窗口 t 与窗口 τ 之间的相似度

$$S_\alpha^{t,\tau} = 1 - \frac{1}{N} \sum_{i=1}^N \left| (PR_\alpha^{(t)})_i - (PR_\alpha^{(\tau)})_i \right|, \quad (8)$$

显然, $S_\alpha^{t,t} = 1$, $S_\alpha^{t,\tau} = S_\alpha^{\tau,t}$, 且 $S_\alpha^{t,\tau} \in [0,1]$, 值越大, 说明两个窗口的全局重要分布越相似, $(PR_\alpha^{(t)})_i$ 指第 t 个窗口第 α 层网络的 PageRank 向量第 i 个分量。

2.2. MT-HITS 中心性计算

基于六阶张量, 使用 MT-HITS 算法, 同时计算节点 i 的 Hub 中心性 x_i 和 Authority 中心性 y_i , 并辅助计算层重要性 z_α , w_β 与时间重要性 u_t , v_τ 。算法迭代过程如下。

1) 初始化中心性向量($s=0$)

为了确保迭代起点公平, 所有向量初始值设为均匀分布。

$$x_i^{(0)} = y_i^{(0)} = \frac{1}{N}, z_\alpha^{(0)} = w_\beta^{(0)} = \frac{1}{L}, u_t^{(0)} = v_\tau^{(0)} = \frac{1}{T}, \quad (9)$$

其中, N 为节点数, L 为层数, T 为时间窗口数。

第 s 步迭代, 按迭代计算更新 6 个向量, 以节点 Hub 中心性 x_i 和层 Authority 中心性 w_β 为例, 其余向量更新逻辑类似。

2) 节点更新

节点 Hub 中心性 x_i 的更新公式为

$$\tilde{x}_i = \sum_{t,\tau,\alpha,\beta,j} \mathbb{T}_{t,\tau,\alpha,\beta,j,i} y_j z_\alpha w_\beta u_t v_\tau, \quad (10)$$

即节点 Hub 得分取决于从该节点指向外部的所有超边的贡献之和, 每条贡献由对方节点重要性、层重要性和时间重要性共同决定。

3) 层更新

层 Authority 中心性 w_β 的更新公式为

$$\tilde{w}_\beta = \sum_{t,\tau,\alpha,i,j} \mathbb{T}_{t,\tau,\alpha,\beta,i,j} x_i y_j z_\alpha u_t v_\tau, \quad (11)$$

即层的 Authority 得分等于汇聚到该层的所有超边贡献之和, 每条超边的贡献由两端节点的 Hub 与 Authority 中心性乘积、来源层重要性和时间窗口重要性共同决定。

每轮迭代后对六个向量进行幂正则化, 将迭代映射转化为多齐次 Perron 特征向量问题, 保证算法收敛到唯一的中心性向量。

$$x_i^{(s)} = \frac{(|\tilde{x}_i| + \varepsilon)^c}{\max_i (|\tilde{x}_i| + \varepsilon)^c}, y_i^{(s)} = \frac{(|\tilde{y}_i| + \varepsilon)^c}{\max_i (|\tilde{y}_i| + \varepsilon)^c}, \dots, \quad (12)$$

其中, 取 $c = \frac{1}{6}$, 常数 $\varepsilon = 10^{-12}$, c 的取值满足 MT-HITS 算法的收敛性条件[15], ε 仅用于防止分母为 0,

对结果不产生实质性影响。同理计算 $\tilde{z}_\alpha$, $\tilde{w}_\beta$, $\tilde{u}_t$, $\tilde{v}_\tau$ 得到 $z_\alpha^{(s)}, w_\beta^{(s)}, u_t^{(s)}, v_\tau^{(s)}$ 。

4) 收敛判断

计算相对误差

$$e^{(s)} = \frac{\|x^{(s)} - x^{(s-1)}\|_\infty + \|y^{(s)} - y^{(s-1)}\|_\infty + \dots + \|v^{(s)} - v^{(s-1)}\|_\infty}{\|x^{(s)}\|_\infty + \|y^{(s)}\|_\infty + \dots + \|v^{(s)}\|_\infty}, \quad (13)$$

当 $e^{(s)} < 10^{-6}$ 或达到最大迭代次数 500 时终止, 输出最终的 x_i 与 y_i 。

Hub 得分 x_i 高的股票倾向于向其他股票传递信息, Authority 得分 y_i 高的股票倾向于接收来自其他股票的信息。该指标融合了双层网络、多窗口的拓扑信息, 且通过 PageRank 相似度来调节跨期自环强度, 更符合金融时间序列的演化规律。

2.3. 双层网络的拓扑结构

1) 网络密度

网络密度是衡量网络中实际存在的边数占最大可能边数的比例, 对于有向无权网络, 其密度定义为

$$\rho = \frac{|E|}{N(N-1)}, \quad (14)$$

其中, $|E|$ 是经过 Top-10% 过滤的有向边数量, N 为股票数量, 密度越大, 表示股票间的信息传递越密集。

2) 层间边重叠度

层间边重叠度可以考察两层网络在强连接结构上的一致性, 对于每个窗口, 分别提取格兰杰层与传递熵层中权重排名前 5% 的边。记为 S_G 和 S_{TE} , 重叠度定义为

$$Overlap = \frac{|S_G \cap S_{TE}|}{\min(|S_G|, |S_{TE}|)}, \quad (15)$$

该值越接近 1, 说明两层网络最重要的信息越一致, 越接近 0, 则说明两者关注的股票对大不相同。

3) 社区检测

采用 Infomap 算法对双层网络进行社区检测, 能够刻画网络的群体分化特征分别对格兰杰层与传递熵层进行社区划分, 统计每个窗口的社区数量。

2.4. 基于 MT-HITS 中心性的投资组合策略模型

设投资组合权重向量为 $w = (w_1, w_2, \dots, w_N)^T$, 历史收益矩阵为 $R \in \mathbb{R}^{T \times N}$, 组合收益为 $r_p = R w$, 在置信水平 α 下, CVaR 模型定义为

$$CVaR_\alpha(w) = VaR_\alpha(w) + \frac{1}{1-\alpha} \mathbb{E} \left[\left(-r_p - VaR_\alpha(w) \right)^+ \right], \quad (16)$$

其中, $(x)^+ = \max(x, 0)$ 。

为进一步引入金融网络结构信息, 本文将归一化后的网络中心性指标作为惩罚项 $\lambda c^T w$ 加入到目标函数中, 构建如下优化模型

$$\min_w [CVaR_\alpha(w) + \lambda c^T w], \quad (17)$$

展开为

$$\min_w \left[VaR_\alpha(w) + \frac{1}{1-\alpha} \mathbb{E} \left((-r_p - VaR_\alpha(w))^+ + \lambda \mathbf{c}^T \mathbf{w} \right) \right]$$

$$\text{s.t. } \sum_{i=1}^N w_i = 1, 0 \leq w_i \leq 0.2,$$

其中, $\mathbf{c}$ 为中心性惩罚向量, λ 为惩罚系数, 即投资组合满足满仓、不允许卖空以及单资产权重上限约束。

3. 实证分析

3.1. 数据来源及预处理

本文选取沪深 300 成分股的日收盘价数据作为研究对象, 样本区间为 2010 年 1 月 2 日至 2025 年 3 月 31 日, 数据来源于 Choice 金融终端数据库。为了保证样本数据的连续性与稳定性, 剔除停牌超过一周的股票, 并对少量缺失数据采用前向填充与后向填充相结合的方法进行处理, 经过数据处理后, 最后共剩余 160 只股票作为研究对象。本文以 120 天(约 6 个月)为窗口长度, 滚动步长为 20 天(约 1 个月), 该长度能够覆盖短期市场风格切换的完整周期, 与 A 股市场的自然月度频率一致, 同时能够保证网络估计具有足够的样本量, 持有期为 10 个交易日(约 2 周), 能够在捕捉短期市场动态与控制交易成本之间取得平衡, CVaR 优化的历史估计窗口设定为 1000 个交易日(约 4 年), 以覆盖完整的市场牛熊周期, 保证尾部风险估计的统计可靠性, 最后在样本区间内共形成 179 个滚动窗口。由于金融价格序列通常具有非平稳性, 直接使用价格数据容易导致伪回归问题, 因此本文采用对数收益率来刻画股票价格波动情况, 其表达式为 $r_t = \ln P_t - \ln P_{t-1}$, P_t 表示股票在时刻 t 的收盘价。

3.2. 网络拓扑结构分析

如图 1 所示, 网络密度演化图中两条曲线基本完全重叠, 这是由于对两层网络均采用 Top-10% 的稀疏化策略, 格兰杰因果层与传递熵层的网络密度在整个样本期内稳定在 0.10 左右, 密度的一致性是比较两层网络结构的前提。




Figure 1. Evolution of network density
图 1. 网络密度演化

从图2可以看出,整个样本期内的边重叠度始终低于0.05,绝大多数时期甚至接近于0,这意味着格兰杰因果层与传递熵层所识别的最强边几乎完全不重叠,使用两种方法捕捉到的信息传递关系是高度正交的,它们分别揭示了金融市场中不同性质的互动机制,若仅使用单层网络,将丢失另一维度的大量子结构信息。因此,极低的边重叠度强有力地印证了构建双层网络的必要性。




Figure 2. Inter-layer edge overlap

图2. 层间边重叠度

图3和图4展示了社区数量随时间的变化特征,两层网络的社区数量均在1~7个之间动态变化,格兰杰层的社区数量波动更为明显,对市场状态的变化更为敏感,表明线性信息传递的模块化程度更容易受到宏观冲击和行业政策的影响。传递熵层社区数量虽然也在波动,但其幅度相对缓和,表明非线性信息流的板块结构具有更强的稳定性。




Figure 3. Number of communities in the granger layer

图3. 格兰杰层社区数量




Figure 4. Number of communities in the transfer entropy layer
图 4. 传递熵层社区数量

3.3. 投资组合优化策略绩效分析

由于金融市场的关联结构会随经济周期和市场环境发生变化,使用静态网络难以捕捉这种时变特征。因此,本文采用滚动窗口方式对表 1 中所列的五种选股策略进行样本外验证。在每一调仓日,首先基于历史窗口数据构建双层金融网络并计算股票的网络中心性指标,随后根据不同选股策略筛选股票池,利用过去 1000 个交易的历史收益数据进行 CVaR 组合优化,得到最优资产权重,在未来 10 个交易日内持有该组合,并于下一调仓日重新计算网络结构与投资权重。在回测中,每次调仓按实际换手率扣除双边 0.1% 的交易成本。为刻画股票在网络中的结构重要性,构建如下几种选股策略。本文基于 MT-HITS 算法计算各节点的 Hub 中心性与 Authority 中心性,分别记为 $H_i^{(t)}$ 和 $A_i^{(t)}$ 。以 Authority 低策略为例,设第 t 个调仓日所有股票的 Authority 中心性向量为 $\mathbf{a}_t \in \mathbb{R}^N$,则股票候选池 $\mathbb{I}_t$ 由 Authority 中心性最低的 K 只股票构成,表示为

$$\mathbb{I}_t = \arg \min_{|S|=K} \sum_{i \in S} a_{t,i}, \quad (18)$$

即对 $a_{t,1}, a_{t,2}, \dots, a_{t,N}$ 按升序排列后,选取最低的 K 只股票。其余选股规则类似,仅选股策略不同,具体如表 1 所示的五类选股策略。

Table 1. Five stock selection strategies based on network centrality
表 1. 不同选股策略

	策略	目标
1	Hub 高策略	选取 Hub 中心性最高的 K 只股票
2	Hub 低策略	选取 Hub 中心性最低的 K 只股票
3	Auth 高策略	选取 Authority 中心性最高的 K 只股票
4	Auth 低策略	选取 Authority 中心性最低的 K 只股票
5	混合策略	对 Hub 与 Authority 指标进行标准化后求平均,选取综合中心性最高的 K 只股票

混合中心性定义为

$$M_i^{(t)} = \frac{\tilde{H}_i^{(t)} + \tilde{A}_i^{(t)}}{2},$$

其中,

$$\tilde{H}_i^{(t)} = \frac{H_i^{(t)} - \min(H^{(t)})}{\max(H^{(t)}) - \min(H^{(t)})},$$

$A_i^{(t)}$ 同理计算。

为评估策略有效性, 本文选取沪深 300 等权重模型与传统的均值 - 方差模型作为基准, 并采用年化收益率、波动率、夏普比率、最大回撤率以及超额收益率五个指标衡量投资组合绩效。其中, 超额收益定义为策略收益相对于沪深 300 等权重基准收益的差值, 不同网络中心性选股策略的投资绩效如表 2 所示, 选股策略的累计收益如图 5 所示。

Table 2. Portfolio performance comparison of alternative stock selection strategies
表 2. 投资组合绩效对比

策略	年化收益	年化波动	夏普	最大回撤	超额收益
Hub 高	-14.80%	25.47%	-0.5811	-76.18%	-18.52%
Hub 低	1.94%	26.26%	0.0740	-57.97%	-2.65%
Auth 高	-1.05%	23.26%	-0.0450	-50.22%	-5.42%
Auth 低	14.35%	24.54%	0.5848	-35.25%	8.93%
混合	-12.95%	24.81%	-0.5222	-79.33%	-16.81%
M-V	3.19%	19.21%	0.1659	-44.28%	-
1/N 等权重	4.06%	21.25%	0.1911	-44.71%	-




Figure 5. Comparison of cumulative returns across alternative stock selection strategies
图 5. 不同选股策略的累计收益对比

从表 2 与图 5 可以看出,使用不同的投资组合优化策略之间存在显著差异。其中,表 2 中是取 $\lambda = 0.1, K = 15$ 得到的结果,Auth 低策略表现出的效果最优,夏普比率为 0.5848,最大回撤为-35.25%,年化收益率达到了 14.35%,显著高于等权重模型(4.06%)与 MV 模型(3.19%),同时获得 8.93%的超额收益。低 Hub 策略也能获得正收益,说明使用边缘股票构建的投资组合具有更强的抗风险能力。相比之下,高中心性与混合中心性策略整体表现出较差的结果,均出现年化收益为负的情况,这表明股票网络中的高中心性节点虽然在风险传递过程中具有较强影响力,但这并不意味着其能够带来更高的投资收益,反而可能由于承担更多系统性风险而导致组合表现更差。

3.4. 稳健性检验

为检验投资策略对关键参数设定的敏感性,本文分别从 CVaR 优化模型中的风险惩罚系数 λ 以及选股数量 K 两个参数在相同持有期内进行稳健性检验。根据上述结果,以最好 Auth 低策略为研究对象,在保持其他参数不变的情况下分别调整参数取值,并比较不同情形下组合的年化收益率和夏普比率。结果如表 3 所示。

Table 3. Robustness check
表 3. 稳健性检验

参数	参数值	年化收益	夏普	最大回撤
改变惩罚系数 λ	0.05	13.35%	0.5509	-39.44%
	0.1	14.35%	0.5848	-35.25%
	0.2	14.43%	0.5707	-30.06%
	0.3	12.50%	0.4848	-30.45%
	0.5	11.43%	0.4294	-32.24%
改变选股数量 K	5	6.81%	0.2297	-53.47%
	10	14.06%	0.5441	-30.78%
	15	14.35%	0.5848	-35.25%

以 $\lambda = 0.1, K = 15$ 为基准,从表 3 中风险惩罚系数 λ 的检验结果来看,当 λ 取值小于 0.1 时,其年化收益也开始下降到 13.35%,当 λ 取大于 0.1 时,年化收益也开始逐渐下降,在取值为 0.1 与 0.2 时,两者年化收益差距最小,说明 Auth 低策略在这个区间内表现比较稳定。从结果可以看出,随着风险惩罚程度的提高,组合收益水平开始呈下降趋势,这表明过强的风险约束会限制组合对收益机会的能力,从而降低整体投资绩效。从对选股数量 K 的检验结果来看,当选股数量由 5 只增加到 15 只时,年化收益率由 6.81%提升到 14.35%,夏普比率由 0.2297 提升至 0.5848,说明适度增加选股数量有助于分散非系统性风险,提高组合的风险调整后的收益水平,综合收益与风险表现,当 $\lambda = 0.1, K = 15$ 时能够取得较好的风险与收益平衡。

综上,在不同参数设定与选股规模下的 Auth 低策略均能保持正收益,说明低 Auth 策略表现并非依赖于某一特定参数取值与特定的选股数量,具有较好的稳定性,说明网络中心性所蕴含的信息具有较强的投资价值,不会因模型参数的适度变化而发生根本改变。

4. 结论

本文基于沪深 300 成分股的日交易数据,采用滚动窗口法构建融合 Granger 因果关系与 Transfer

Entropy 信息流的双层动态金融网络, 并使用六阶张量融合时间维度与层间关系, 再用 MT-HITS 算法测度股票在双层网络中的 Hub 中心性与 Authority 中心性, 在此基础上, 构建网络中心性选股策略, 并结合 CVaR 模型进行投资组合优化。

实证结果表明, 不同的网络中心性指标的投资价值是有显著差异的, 使用低 Authority 策略(Auth 低)效果最优, 其年化收益达到了 14.35%, 夏普比率为 0.5848, 整体优于基准策略。而高中心性策略整体表现出较差的结果, 与混合策略都出现负收益的情况, 说明处于网络核心位置的股票虽然具有较强的风险传递能力, 但同时也承担着更高的系统性风险。相反, 存在网络边缘的股票可能由于市场的关注度较低而存在一定的投资价值, 从而能够获得一个更优的风险收益表现。此外, CVaR 模型通过关注尾部风险并使用动态调整资产权重, 这在一定程度上提升了投资组合的稳定性和对风险的控制能力。

基于此, 相关部门应该加强对市场的核心股票和风险传递路径的监管, 并且完善对风险的预警机制; 投资者可以把网络中心性指标进一步纳入到投资决策模型中, 以提升资产的组合配置效率和风险管理水平; 同时, 应该进一步地推动金融市场关联数据的共享, 为复杂网络分析在投资组合管理中的应用创造更好的条件。

基金项目

湖南省教育厅科学研究重点项目(25A0379); 2024 年度湖南省普通本科高校教学改革研究重点项目(202401000940); 吉首大学研究生校级科学研究项目(Jdy25040)。

参考文献

- [1] Markowitz, H. (1952) Portfolio Selection. *The Journal of Finance*, **7**, 77-91. <https://doi.org/10.1111/j.1540-6261.1952.tb01525.x>
- [2] Rockafellar, R.T. and Uryasev, S. (2002) Conditional Value-at-Risk for General Loss Distributions. *Journal of Banking & Finance*, **26**, 1443-1471. [https://doi.org/10.1016/s0378-4266\(02\)00271-6](https://doi.org/10.1016/s0378-4266(02)00271-6)
- [3] Watts, D.J. and Strogatz, S.H. (1998) Collective Dynamics of 'Small-World' Networks. *Nature*, **393**, 440-442. <https://doi.org/10.1038/30918>
- [4] Barabási, A. and Albert, R. (1999) Emergence of Scaling in Random Networks. *Science*, **286**, 509-512. <https://doi.org/10.1126/science.286.5439.509>
- [5] Bonacich, P. (1972) Factoring and Weighting Approaches to Status Scores and Clique Identification. *The Journal of Mathematical Sociology*, **2**, 113-120. <https://doi.org/10.1080/0022250x.1972.9989806>
- [6] Mantegna, R.N. (1999) Hierarchical Structure in Financial Markets. *The European Physical Journal B*, **11**, 193-197. <https://doi.org/10.1007/s100510050929>
- [7] Peralta, G. and Zareei, A. (2016) A Network Approach to Portfolio Selection. *Journal of Empirical Finance*, **38**, 157-180. <https://doi.org/10.1016/j.jempfin.2016.06.003>
- [8] 牛晓健, 梁张诚. 基于网络中心性视角的股指增强投资策略研究[J]. 世界经济文汇, 2020(6): 104-120.
- [9] Li, Y., Jiang, X.F., Tian, Y., Li, S.P. and Zheng, B. (2019) Portfolio Optimization Based on Network Topology. *Physica A: Statistical Mechanics and its Applications*, **515**, 671-681. <https://doi.org/10.1016/j.physa.2018.10.014>
- [10] Kivelä, M., Arenas, A., Barthelemy, M., Gleeson, J.P., Moreno, Y. and Porter, M.A. (2014) Multilayer Networks. *Journal of Complex Networks*, **2**, 203-271. <https://doi.org/10.1093/comnet/cnu016>
- [11] Boccaletti, S., Bianconi, G., Criado, R., del Genio, C.I., Gómez-Gardeñes, J., Romance, M., et al. (2014) The Structure and Dynamics of Multilayer Networks. *Physics Reports*, **544**, 1-122. <https://doi.org/10.1016/j.physrep.2014.07.001>
- [12] Billio, M., Getmansky, M., Lo, A.W. and Pelizzon, L. (2012) Econometric Measures of Connectedness and Systemic Risk in the Finance and Insurance Sectors. *Journal of Financial Economics*, **104**, 535-559. <https://doi.org/10.1016/j.jfineco.2011.12.010>
- [13] Diebold, F.X. and Yilmaz, K. (2014) On the Network Topology of Variance Decompositions: Measuring the Connectedness of Financial Firms. *Journal of Econometrics*, **182**, 119-134. <https://doi.org/10.1016/j.jeconom.2014.04.012>
- [14] Arrigo, F. and Tudisco, F. (2019) Multi-Dimensional, Multilayer, Nonlinear and Dynamic Hits. In: Berger-Wolf, T. and

-
- Chawla, N., Eds., *Proceedings of the 2019 SIAM International Conference on Data Mining*, Society for Industrial and Applied Mathematics, 369-377. <https://doi.org/10.1137/1.9781611975673.42>
- [15] Lv, L.S., Zhang, K., Bardou, D., Li, X., Zhang, T. and Xue, W. (2021) HITS Centrality Based on Inter-Layer Similarity for Multilayer Temporal Networks. *Neurocomputing*, **423**, 220-235. <https://doi.org/10.1016/j.neucom.2020.10.040>
- [16] 王纲金, 吴昊钰, 谢赤. 基于多层关联网络的投资组合优化研究[J]. 系统工程理论与实践, 2022, 42(4): 937-957.
- [17] 赵霞, 许澜涛, 孙晓, 等. 带耦合时序网络、重要性节点识别及投资组合研究——以股票市场为例[J]. 应用概率统计, 2023, 39(1): 117-131.
- [18] 杨剑楠, 刘建国, 郭强. 基于层间相似性的时序网络节点重要性研究[J]. 物理学报, 2018, 67(4): 279-286.
- [19] 刘超, 许澜涛. 多层时序网络视角下的最优投资组合策略研究[J]. 中国管理科学, 2025, 33(9): 46-56.
- [20] Onnela, J.P., Kaski, K. and Kertesz, J. (2004) Clustering and Information in Correlation Based Financial Networks. *The European Physical Journal B: Condensed Matter*, **38**, 353-362. <https://doi.org/10.1140/epjb/e2004-00128-7>