

中国金融系统性风险：基于收益和情绪的复杂网络分析

刘佳奇

上海理工大学管理学院系统科学系，上海

收稿日期：2025年2月17日；录用日期：2025年4月1日；发布日期：2025年4月9日

摘要

自2008年金融危机后，系统性金融风险研究受到广泛关注，遏制风险溢出、构建传播网络及识别关键节点是提升金融市场风险管理能力的关键。本研究构建了基于股票收益和投资者情绪的双层复杂网络，结合皮尔逊、肯德尔相关系数及互信息方法捕捉市场波动和投资者行为，以DCC-GJR-GARCH-CoVAR模型衡量银行、证券、保险、信托和房地产等金融机构的风险溢出效应，并通过信息熵法聚合中心性指标，揭示不同网络中中心性对系统性风险的影响。结果表明，加入情绪因素和互信息构建的网络可提高模型拟合度，更准确刻画风险传递路径，不同网络位置的公司对系统性风险的贡献存在显著差异，突显市场参与者在网络中的重要性，为风险监测和政策制定提供新视角。

关键词

复杂网络，系统性金融风险，投资者情绪，相关系数

Systemic Financial Risk in China: A Complex Network Analysis Based on Returns and Sentiment

Jiaqi Liu

Department of Systems Science, Business School, University of Shanghai for Science and Technology, Shanghai

Received: Feb. 17th, 2025; accepted: Apr. 1st, 2025; published: Apr. 9th, 2025

Abstract

Since the 2008 financial crisis, systemic financial risk research has received widespread attention. Containing risk spillovers, constructing transmission networks, and identifying key nodes are

crucial to enhancing the financial market's risk management capabilities. This study constructs a dual-layer complex network based on stock returns and investor sentiment, employing Pearson correlation, Kendall correlation, and mutual information methods to capture market co-movement characteristics and investor behavior patterns. The DCC-GJR-GARCH-CoVAR model is utilized to measure the risk spillover effects among financial institutions, including banks, securities firms, insurance companies, trust institutions, and real estate firms. Additionally, centrality indicators are aggregated using the entropy method to reveal the impact of centrality in different networks on systemic risk. The results indicate that incorporating sentiment factors and constructing networks using mutual information enhances model fitting accuracy and provides a more precise depiction of risk transmission pathways. Moreover, firms occupying different network positions exhibit significant variations in their contributions to systemic risk, underscoring the importance of market participants in the network structure. These findings offer new insights for risk monitoring and policy formulation.

Keywords

Complex Networks, Systemic Financial Risks, Investor Sentiment, Correlation Coefficients

Copyright © 2025 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

系统性金融风险指金融问题蔓延至整个金融体系和实体经济的重大风险。2008年金融危机以及中国的“钱荒”和“股灾”事件暴露了金融体系的脆弱性，推动了加强监管的措施，同时也促使学界和业界对系统性风险的度量方法进行深入研究。本研究旨在构建创新的分析框架，为系统性风险管理提供科学依据。

“系统性金融风险”概念自20世纪80年代起广泛应用于金融领域。Bernanke指出金融体系健康状况通过信贷市场和其他经济活动影响经济波动，从而间接提出了系统性风险的概念[1]，Kaufman进一步明确其对银行业和金融体系的影响[2]。VaR模型作为标准化风险管理工具，由J.P. Morgan的RiskMetrics系统提出[3]，但其忽略了金融机构间的关联性。为弥补这一缺陷，Adrian和Brunnermeier提出了CoVaR方法[4]，后续研究结合GARCH模型进一步优化了该方法，如Tobias和Brunnermeier提出了动态度量方法[5]，Huang和Zhou基于Copula模型分析了中国金融市场的风险传递[6]，Karimalis和Nomikos则研究了欧元区金融体系的风险[7]。DCC-GARCH模型由Engle提出，可捕捉金融市场中的动态相关性[8][9]，DCC-GJR-GARCH-CoVaR模型进一步结合了GJR-GARCH的非对称效应，提高了风险测度的精确性。

近年来，复杂网络方法在金融领域的应用日益广泛。Mantegna提出最小生成树(MST)用于分析资产相关性[10]，Kritzman等人提出基于投资组合的网络结构分析方法[11]，Billio等人通过构建金融机构间的相依网络探讨了风险扩散机制[12]。Wen的研究进一步揭示了金融机构与金融科技机构间的极端风险溢出效应[13]。与此同时，市场情绪在系统性风险中的作用亦受到关注。Baker和Wurgler指出市场情绪影响股票市场风险溢价[14]，Tetlock发现媒体情绪变化可预测市场波动[15]，Bollen等人通过Twitter情绪分析构建市场情绪指数并验证其对股市波动的预测能力[16]，Preis等人则通过Google搜索量分析市场情绪对金融市场的影响[17]。Wang的研究表明，投资者情绪波动影响股票收益和价格变化，进而影响风

险传递[18]。

结合复杂网络与情绪网络的分析框架，有助于揭示市场情绪在系统性风险中的作用。Arouba 和 Diebold 指出，市场情绪的突变往往预示金融市场的转折，情绪网络可作为预警工具[19]。通过构建基于投资者情绪的网络分析，可以识别金融市场中的关键节点和风险传播路径，为系统性风险管理提供新思路。因此，本文拟基于股票收益与投资者情绪构建双层复杂网络，并结合 DCC-GJR-GARCH-CoVaR 模型量化金融机构间的风险溢出效应，以期提升系统性风险测度的准确性，为宏观审慎监管提供理论支持。

2. 上市金融机构系统性金融风险溢出水平的度量

上市金融机构的系统性金融风险溢出水平可通过多种指标和方法来度量，旨在评估其对金融系统的影响及在市场冲击下的风险传导效应。本文采用 DCC-GJR-GARCH 模型，结合波动性建模与动态相关性分析，进行系统性风险溢出水平的度量。

DCC-GJR-GARCH 模型的建立需从基础的 ARMA 模型和 GARCH 模型入手，逐步引入非对称波动效应和动态相关性分析。

2.1. ARMA 模型

ARMA 模型(自回归移动平均模型)用于描述单变量时间序列的自回归与移动平均关系，捕捉数据的趋势与周期性变化，为波动性模型的构建奠定基础。

ARMA (p, q)模型形式如下：

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \cdots + \phi_p y_{t-p} + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \cdots + \theta_q \epsilon_{t-q} + \epsilon_t$$

其中， y_t 是时间序列的观测值， c 是常数项(截距项)， $\phi_1, \phi_2, \dots, \phi_p$ 是自回归系数， $\theta_1, \theta_2, \dots, \theta_q$ 是移动平均系数， ϵ_t 是白噪声误差，通常假设其服从正态分布 $N(0, \sigma^2)$ 。

2.2. ARCH 模型

ARCH 模型处理异方差性，描述波动率聚集现象，即大波动后通常伴随大波动。模型通过引入延迟的残差平方项来描述波动性，表达式为：

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \epsilon_{t-i}^2$$

其中， σ_t^2 是时间 t 的条件方差， α_0 是常数项， α_i 是模型参数。

2.3. GARCH 模型

GARCH 模型增强了对波动性的建模，通过考虑过去条件方差的影响，动态调整波动性。表达式为：

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \epsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2$$

其中， ω 是常数项， α_i 和 β_j 是 GARCH 模型的参数。

GARCH (1, 1)模型通常能够有效刻画大多数金融时间序列的波动特性。然而，正态分布假设未能充分捕捉金融时间序列中的尖峰和厚尾现象。因此，本文引入 t 分布来更好地描述极端事件的发生概率和波动性，从而提高对尾部风险和极端事件影响的估计精度。GARCH-t 模型假设残差服从 t 分布，其概率密度函数为：

$$f(\epsilon_t | \sigma_t^2, \nu) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\pi\nu}\Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{\epsilon_t^2}{\nu\sigma_t^2}\right)^{-\frac{\nu+1}{2}}$$

其中， $\Gamma(\cdot)$ 是伽玛函数， σ_t^2 是时间 t 的条件方差， ν 是 t 分布的自由度参数。

2.4. GJR-GARCH 模型

GJR-GARCH 模型引入非对称波动效应，区分正负冲击对波动性的不同影响。模型形式为：

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \epsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 + \gamma I_{t-1} \epsilon_{t-1}^2$$

其中， γ 是非对称波动参数， I_{t-1} 是指示函数。

2.5. DCC-GJR-GARCH 模型

DCC-GJR-GARCH 模型结合了 GJR-GARCH 的波动特性和 DCC 模型的动态相关性，通过对每个变量估计 GJR-GARCH 模型，计算标准化残差，进而估计 DCC 模型，捕捉多变量时间序列的波动和相关性变化。

构建步骤如下：

多变量 GJR-GARCH 模型估计：对每个变量 X_i ，估计 GJR-GARCH 模型。

$$\sigma_{i,t}^2 = \omega_i + \sum_{j=1}^{p_i} \alpha_{i,j} \epsilon_{i,t-j}^2 + \sum_{k=1}^{q_i} \beta_{i,k} \sigma_{i,t-k}^2 + \gamma_i I_{t-1} \epsilon_{i,t-1}^2$$

计算标准化残差：利用估计的 GJR-GARCH 模型，计算每个变量 X_i 在时间 t 的标准化残差 $z_{i,t} = \frac{\epsilon_{i,t}}{\sigma_{i,t}}$ 。

DCC 模型估计：使用标准化残差序列 $\{z_{i,t}\}$ 估计 DCC 模型。 $R_t = D_t Q_t D_t$ ，

其中， D_t 是对角矩阵，其对角线元素为 $\sqrt{\sigma_{1,t}^2}, \sqrt{\sigma_{2,t}^2}, \dots, \sqrt{\sigma_{k,t}^2}$ 。

Q_t 是条件相关系数矩阵，通常由以下形式表示：

$$Q_t = (1 - \lambda)Q + \lambda z_t z_t'$$

其中， Q 是长期平均相关系数矩阵， λ 是控制相关系数变化速度的参数。

2.6. CoVaR 方法

CoVaR 方法通过考察当某一机构 i 损失达到其 VaR 水平时，其他金融系统或机构的最大潜在损失，揭示了风险在金融体系中的传染机制。CoVaR 的定义为系统 s 在条件 i 处于其 VaR 水平时的条件在险值，公式为：

$$P(R_s \leq \text{CoVaR}_q^{si} | R_i = \text{VaR}_q^i) = q,$$

其中， R_s 为金融系统 s 的收益率， CoVaR_q^{si} 表示系统在特定条件下的最大损失。通过计算 ΔCoVaR ，可以进一步量化单个机构对系统性风险的边际贡献，表达式如下：

$$\Delta\text{CoVaR}_q^{si} = \text{CoVaR}_q^{si}(\text{VaR}_{\text{stress}}) - \text{CoVaR}_q^{si}(\text{VaR}_{\text{normal}}),$$

本文结合 DCC-GJR-GARCH-CoVaR 模型进行实证分析。我们得到了系统性风险的测度公式：

$$\Delta\text{CoVaR}_q^{si} = \text{CoVaR}_q^{si}(\text{VaR}_{\text{stress}}) - \text{CoVaR}_q^{si}(\text{VaR}_{\text{normal}})。$$

3. 构建金融市场的复杂网络：收益率网络与投资者情绪网络的分析

3.1. 构建金融股票收益率网络

根据 Mantegna 的方法，计算股票收益率的相关性构建金融市场网络[20]。假设第 i 只股票在时间 t 的对数收益率为 $r_{i,t}$ ，定义如下：

$$r_{i,t} = \ln(P_{i,t}) - \ln(P_{i,t-1}),$$

其中， $P_{i,t}$ 和 $P_{i,t-1}$ 分别为第 i 只股票在时间 t 和 $t-1$ 的收盘价。节点为股票，边权为收益率之间的相关系数[21] [22]。

3.2. 引入投资者情绪网络

尽管收益率网络能够有效描述资产价格之间的联动性和风险传导机制，但它未能全面反映市场中投资者情绪的影响。金融市场的波动不仅受基本面信息驱动，还受到投资者情绪的显著影响[23]。为了弥补收益率网络的不足，本文进一步构建了投资者情绪网络，以揭示情绪因素在市场风险中的作用。投资者情绪指标(Investor Sentiment Ratio, ISR)定义如下：

$$\text{ISR}_{i,t} = \frac{\sum_{t=1}^N H_{i,t} - O_{i,t}}{\sum_{t=1}^N O_{i,t} - L_{i,t}},$$

其中， $H_{i,t}$ ， $O_{i,t}$ 和 $L_{i,t}$ 分别为第 i 只股票在时间 t 的最高价、开盘价和最低价。该指标反映了投资者在短期内的情绪状态，并通过最近五天的移动窗口平滑处理以减少噪声[24]。构建情绪网络的节点代表股票，边的权重由情绪指标之间的相关性确定，这能够揭示市场中的非理性行为和情绪驱动的风险传播。

3.3. 金融机构间股票关联度量方法

通过皮尔逊相关系数、肯德尔相关系数与互信息计算收益率矩阵和情绪矩阵的相关性，构建相关性矩阵，并基于该矩阵分析股票网络的拓扑结构，以更全面地揭示市场中线性与非线性风险传导机制。

皮尔逊相关系数(Pearson correlation coefficient)是衡量两个变量之间线性关系强度和方向的统计量。表达式为：

$$r_{XY} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}}$$

其中， n 是样本大小， X_i 和 Y_i 分别是变量 X 和 Y 的单个样本数据点， \bar{X} 和 \bar{Y} 分别是变量 X 和 Y 的样本均值。

肯德尔相关系数(Kendall's tau coefficient)是一种用于衡量两个变量之间相关性的统计量，它不依赖于数据的分布形态，通常用于处理非正态分布或含有异常值的数据。表达式为：

$$\tau = 2 \Pr\left[\left(X_i - X_j\right)\left(Y_i - Y_j\right) > 0\right] - 1$$

其中，肯德尔相关系数的取值范围是[-1, 1]。

互信息(Mutual Information, MI)是衡量两个变量之间共享信息的量。相比于传统的皮尔逊相关系数，互信息能够捕捉变量间的非线性依赖关系[25]。互信息基于信息熵理论定义，其计算公式如下：

$$I(X, Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)}$$

其中, $p(x)$ 和 $p(y)$ 分别表示变量 X 和 Y 的边际概率分布, $p(x, y)$ 表示其联合概率分布。

3.4. 金融机构间股票的网络滤波

在研究金融系统性风险的复杂网络分析中, 相关系数矩阵的滤波处理是构建网络结构的关键步骤, 常用的方法包括阈值法、最小生成树法[10]和平面最大滤波图(Planar Maximally Filtered Graph, PMFG) [26]。阈值法通过设定相关系数阈值保留强相关关系, 但易导致信息丢失; MST 方法保留最强相关性, 但可能忽略次优关联, 导致网络过于稀疏; 相比之下, PMFG 方法通过构建平面图保留更多重要关联, 能够捕捉复杂的多变量依赖关系, 更好地揭示系统性风险传播路径, 因此本研究选择 PMFG 进行滤波。

3.5. 网络拓扑结构指标

(1) 加权度

加权度(Weighted Degree)是考虑连接强度的网络指标, 定义为:

$$W_i^k = \sum_j w_{ij}^k$$

其中, w_{ij} 是节点 i 和节点 j 之间边的权重。 W_i 为节点 i 在网络中重要性的度量, K 表示第 k 层节点。

(2) PageRank

PageRank 为网页分配分数并进行排名, 将每个网页视为图的节点, 页面之间的链接为边[27]。算法如下:

$$PR(u) = (1-d) + d \sum_{u \in B(u)} \frac{PR(u)}{N_u}$$

其中 $B(u)$ 是链接到页面 u 的页面的总和, $PR(u)$ 表示 PageRank 算法分配给页面 u 的分数, N_u 表示页面 u 的出链数量, d 表示阻尼系数(通常等于 0.85)。初始时, 所有节点的 PageRank 值为 $1/n$, n 为节点总数。

(3) 特征向量中心性

特征向量中心性衡量节点的影响力, 节点与影响力较大的节点连接时, 其特征向量中心性较高。将第 k 层的向量 X^k 表示为 $(x_1^k, x_2^k, \dots, x_n^k)$, 其中 x_i^k 是第 k 层中节点 i 的特征向量中心性, 则 X^k 可以表示为:

$$W^k X^k = \lambda^{\max^k}$$

其中, W^k 是网络在第 k 层的权重或邻接矩阵, X^k 是 W^k 的特征向量, λ^{\max^k} 是 W^k 的最大特征值。

(4) 紧密中心性

紧密中心性(closeness centrality)衡量节点与其他节点的连接密度及其重要性, 公式为:

$$C_i = \frac{n-1}{\sum_{j \neq i} d_{ij}}$$

其中, d_{ij} 是节点 i 到节点 j 的加权距离, n 是网络中节点的总数。

所有这些指标都适用于描述单层网络结构, 而在多层网络中需要对各层指标进行聚合。

(5) 聚合多层中心性指数

通过信息熵方法, 将基于皮尔森, 肯德尔相关系数和互信息构建的三层网络中心性指标聚合。具体步骤为:

对每层中心性指标标准化; 计算每层标准化中心性指标的熵, 得出权重; 使用权重加权合并标准化

后的中心性指标，得出综合中心性指标。加权公式为：

$$X_{\text{combined}} = \sum_{i=1}^n \frac{H(X_{i,\text{norm}})}{\sum_{k=1}^n H(X_{k,\text{norm}})} \cdot X_{i,\text{norm}}$$

其中， X_{combined} 为综合的中心性指标， n 为网络层的总数。 $H(X_{i,\text{norm}})$ 为第 i 层网络标准化后中心性指标的熵。

$X_{i,\text{norm}}$ 为第 i 层网络标准化后的中心性指标。

4. 数据与实证分析

本文选取的样本基于证监会行业分类，考虑了以下四个方面：时间跨度长、金融机构数量多、数据接近当前、行业覆盖广泛。样本数据来自 2013 年 1 月 4 日至 2022 年 12 月 30 日的 A 股上市金融机构股票价格，共 33 家金融机构，包括 16 家银行、7 家证券公司、3 家保险公司、3 家信托公司和 4 家房地产公司(见表 1)。

Table 1. Names of financial institutions
表 1. 金融机构名称

银行		证券	保险	信托	房地产
工商银行	浦发银行	中信证券	中国人寿	五矿资本	万科 A
建设银行	平安银行	东方财富	中国平安	陕国投	保利地产
农业银行	光大银行	华泰证券	中国太保	越秀资本	华夏幸福
中国银行	民生银行	招商证券			华侨城 A
招商银行	宁波银行	海通证券			
交通银行	北京银行	广发证券			
兴业银行	华夏银行	光大证券			
中信银行	南京银行				

本文使用 33 家上市金融机构的日股票收益率，计算其条件风险价值，并按年分析中国 33 家金融机构的系统性风险溢出(见表 2)。2013~2014 年，市场稳定，政策支持股市上涨，系统性风险较低。2015 年 6 月股市高点后大幅下跌，导致市场恐慌，系统性风险上升。2015 年股灾后，市场恢复平稳，投资者信心回升，风险下降。2017 年中国经济增长稳健，市场信心回升，系统性风险降低。2018 年，受中美贸易战和国内经济放缓影响，股市大幅下跌，系统性风险显著增加。

Table 2. Ranking of systemic risk spillover effects of financial institutions
表 2. 金融机构系统性风险溢出效应排名

	2013		2014		2015		2017		2018	
	ΔCoVAR	Rank								
保利发展	0.01096	31	0.00869	31	0.01283	32	0.01172	1	0.00380	33
北京银行	0.01673	22	0.01248	22	0.02323	26	0.00751	20	0.01392	25
东方财富	0.00929	32	0.00817	32	0.01834	30	0.00519	32	0.01165	31
工商银行	0.01573	25	0.01223	25	0.02514	23	0.00616	29	0.01543	20
光大银行	0.00172	33	0.00306	33	0.00867	33	0.00717	24	0.01579	18
光大证券	0.02114	10	0.01765	4	0.03358	3	0.00919	13	0.01666	14
广发证券	0.02206	5	0.01686	9	0.03316	6	0.00981	9	0.01729	9
海通证券	0.02223	4	0.01773	2	0.03355	4	0.00916	14	0.01778	7

续表

华侨城 A	0.01813	18	0.01377	18	0.02414	25	0.00787	18	0.01692	11
华泰证券	0.02309	1	0.01770	3	0.03407	2	0.01022	7	0.01874	4
华夏幸福	0.01424	26	0.01114	27	0.01881	29	0.00665	25	0.01382	26
华夏银行	0.01857	16	0.01416	15	0.02767	17	0.00861	15	0.01642	16
建设银行	0.01640	23	0.01302	20	0.02850	15	0.00751	21	0.01622	17
交通银行	0.01900	14	0.01400	16	0.02772	16	0.00778	19	0.01562	19
民生银行	0.01759	19	0.01389	17	0.02602	21	0.00920	12	0.01534	21
南京银行	0.01263	29	0.00986	29	0.01913	28	0.00620	27	0.01084	32
宁波银行	0.01998	11	0.01489	13	0.02869	14	0.00838	17	0.01658	15
农业银行	0.01688	21	0.01210	26	0.02606	20	0.00604	30	0.01481	23
平安银行	0.01851	17	0.01472	14	0.02922	12	0.00930	11	0.01675	13
浦发银行	0.01881	15	0.01495	12	0.02891	13	0.00616	28	0.01361	27
陕国投 A	0.01390	27	0.01236	23	0.02450	24	0.00593	31	0.01205	29
万科 A	0.01691	20	0.01310	19	0.02739	18	0.00643	26	0.01681	12
五矿资本	0.01148	30	0.00878	30	0.01689	31	0.00402	33	0.01298	28
兴业银行	0.01970	12	0.01563	11	0.02996	11	0.00992	8	0.01696	10
越秀资本	0.01365	28	0.01094	28	0.02039	27	0.00724	23	0.01191	30
招商银行	0.02161	7	0.01644	10	0.03128	10	0.01052	3	0.01881	3
招商证券	0.02140	8	0.01720	7	0.03229	7	0.00936	10	0.01738	8
中国平安	0.02182	6	0.01722	6	0.03180	9	0.01051	4	0.01911	2
中国人寿	0.02117	9	0.01692	8	0.03199	8	0.01027	6	0.01840	6
中国太保	0.02276	2	0.01826	1	0.03560	1	0.01093	2	0.01963	1
中国银行	0.01605	24	0.01233	24	0.02546	22	0.00738	22	0.01517	22
中信银行	0.01921	13	0.01257	21	0.02628	19	0.00850	16	0.01460	24
中信证券	0.02237	3	0.01735	5	0.03319	5	0.01035	5	0.01847	5
	2019		2020		2021		2022			
	ΔCoVAR	Rank	ΔCoVAR	Rank	ΔCoVAR	Rank	ΔCoVAR	Rank		
保利发展	0.00187	33	0.00169	33	0.00223	33	0.00283	33		
北京银行	0.01322	27	0.01531	28	0.01126	24	0.01333	24		
东方财富	0.01284	28	0.01437	30	0.01071	27	0.01291	27		
工商银行	0.01354	25	0.01530	29	0.01064	28	0.01175	30		
光大银行	0.01384	23	0.01678	21	0.01202	20	0.01529	18		
光大证券	0.01710	10	0.01882	10	0.01327	15	0.01581	14		
广发证券	0.01764	6	0.02036	7	0.01483	8	0.01782	8		
海通证券	0.01771	5	0.02052	4	0.01473	9	0.01812	6		
华侨城 A	0.01606	11	0.01800	12	0.01120	25	0.01588	13		
华泰证券	0.01798	2	0.02121	2	0.01604	5	0.01909	3		
华夏幸福	0.01268	29	0.01534	27	0.00826	32	0.01186	29		
华夏银行	0.01540	15	0.01729	18	0.01292	16	0.01537	17		
建设银行	0.01470	19	0.01771	13	0.01214	19	0.01396	23		
交通银行	0.01433	21	0.01701	20	0.01161	23	0.01406	22		
民生银行	0.01442	20	0.01642	22	0.01359	13	0.01490	20		
南京银行	0.00993	32	0.01146	32	0.00945	31	0.00999	32		

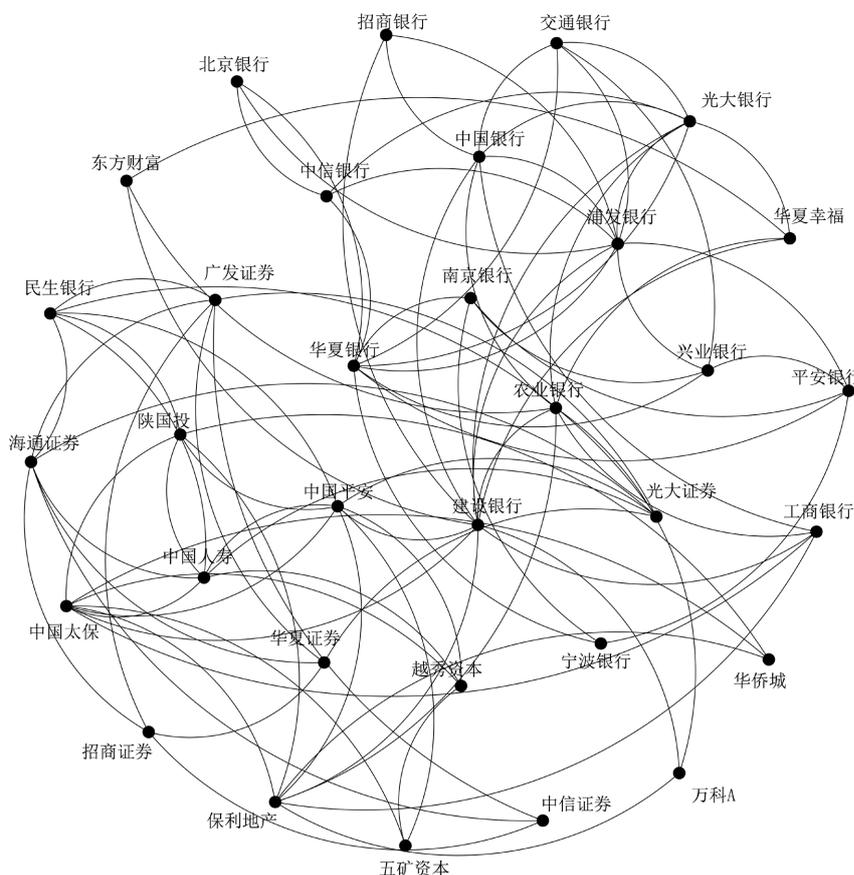


Figure 4. Kendall network diagram of emotion network in the first quarter of 2015
 图 4. 2015 年第一季度情绪网络的 Kendall 网络图

每季度构建一个多层网络，比较同一时期的不同层次网络及不同时期的同一层次网络，发现节点连接的数量和对象并不固定。例如，图 1~图 4 中的四层网络拓扑结构各异，表明每一层可能捕捉到不同的信息。因此，多层网络能够整合比单层网络更多的信息。表 3 提供了总体及各层中心性度量的描述性统计。

Table 3. Descriptive statistics of centrality metrics
 表 3. 中心性度量的描述性统计

网络	网络结构特征	数据个数	平均值	最大值	最小值	标准差
Pearson	加权度	1188	8.0488	29.8020	0.5627	4.7587
	pagerank	1188	0.0303	0.1115	0.0170	0.0133
	特征向量中心性	1188	0.4162	1.0000	0.0899	0.2203
	紧密中心性	1188	0.4080	0.7805	0.2238	0.0771
Kendall	加权度	1188	6.2249	25.8444	0.3959	3.7111
	pagerank	1188	0.0303	0.0873	0.0171	0.0132
	特征向量中心性	1188	0.3970	1.0000	0.0873	0.2109
	紧密中心性	1188	0.4116	0.6957	0.2462	0.0747

续表

互信息	加权度	1188	3.1478	12.9121	0	2.6752
	pagerank	1188	0.0303	0.0870	0	0.0180
	特征向量中心性	1188	0.1232	0.4409	0	0.1230
	紧密中心性	1188	0.3602	0.7989	0	0.1824
情绪 Pearson	加权度	1188	7.8465	24.0143	0.6150	4.4314
	pagerank	1188	0.0303	0.0870	0.0170	0.0124
	特征向量中心性	1188	0.4296	1.0000	0.1040	0.2241
	紧密中心性	1188	0.3974	0.6809	0.2520	0.0739
情绪 Kendall	加权度	1188	6.0105	23.5990	0.4010	3.4152
	pagerank	1188	0.0303	0.0972	0.0170	0.0126
	特征向量中心性	1188	0.4082	1.0000	0.0928	0.2134
	紧密中心性	1188	0.4009	0.6957	0.2286	0.0742

为了确保分析的全面性和准确性,本文选择了收益率复杂网络和情绪复杂网络的加权度、PageRank、特征向量中心性和紧密中心性作为自变量,这些变量能够有效反映网络中各节点的重要性及其对系统性风险的影响。同时,控制变量的选取考虑了公司财务状况及盈利能力,具体包括净利润同比增长率、净资产同比增长率、净资产收益率(ROE)、总资产同比增长率、总资产报酬率(ROA)、权益乘数、对数负债规模(LN 负债)和对数资产规模(LN 资产)等指标。这些变量不仅能够有效控制公司内部财务因素的干扰,还能深入探讨公司财务特征与市场结构特征对风险传递和市场波动的影响。

4.1. R² 检验与 DCC-GJR-GARCH-CoVaR 模型的有效性分析

为了评估 CoVaR 指标对系统性风险的解释能力,本文采用 R² 检验来衡量传统 GARCH-CoVaR 和 DCC-GJR-GARCH-CoVaR 计算的 CoVaR 值与关键影响变量之间的拟合优度。

Table 4. GARCH-CoVaR Goodness of fit

表 4. GARCH-CoVaR 模型拟合优度

模型	R	R ²	调整后 R ²	变更统计资料				
				R ² 变更	F 值变更	df1	df2	显著性 F 值变更
1	0.415	0.172	0.160	0.172	14.785	16	1138	0.000

Table 5. DCC-GJR-GARCH-CoVaR Goodness of fit

表 5. DCC-GJR-GARCH-CoVaR 模型拟合优度

模型	R	R ²	调整后 R ²	变更统计资料				
				R ² 变更	F 值变更	df1	df2	显著性 F 值变更
1	0.627	0.393	0.384	0.393	46.021	16	1138	0.000

从表 4 和表 5 所示, DCC-GJR-GARCH-CoVaR 模型的 R² (0.392) 显著高于传统 GARCH-CoVaR 模型的 R² (0.172)。DCC-GJR-GARCH-CoVaR 模型在解释系统性风险方面具有更强的适用性和有效性。相比传统 GARCH-CoVaR 模型,该模型不仅能够更好地捕捉市场动态相关性和非对称波动效应,还能显著提

高系统性风险的测度精度。因此,本文采用 DCC-GJR-GARCH-CoVaR 模型进行实证分析,以期系统性风险管理提供更科学的量化依据。

4.2. 互信息(Mutual Information)与 R² 检验分析

在本研究中,为了进一步提升对系统性风险溢出的解释能力,我们引入互信息(Mutual Information, MI)构建复杂网络,利用其计算得到的中心性指标进行 R² 检验,评估其对模型拟合度的影响,以验证互信息在金融系统性风险中的有效性。

Table 6. Goodness of fit without mutual information
表 6. 无互信息拟合优度

模型	R	R ²	调整后 R ²	变更统计资料				
				R ² 变更	F 值变更	df1	df2	显著性 F 值变更
1	0.569	0.323	0.314	0.323	34.010	16	1138	0.000

Table 7. Goodness of fit with mutual information
表 7. 有互信息拟合优度

模型	R	R ²	调整后 R ²	变更统计资料				
				R ² 变更	F 值变更	df1	df2	显著性 F 值变更
1	0.627	0.393	0.384	0.393	46.021	16	1138	0.000

从表 6 和表 7 的回归分析结果来看,未引入互信息时,模型的 R² 值为 0.323,而引入互信息后,R² 提升至 0.393。这表明,互信息中心性指标的加入增强了模型的解释能力,提高了系统性风险溢出的测度精度。

4.3. 面板回归分析

由于选择的特征变量较多,且不知道在 T 检验下能否显著,变量之间是否存在共线性,所以我们在回归前应该先做检验并剔除不合理的变量。本文选用逐步回归法来筛选变量,如表 8 所示。

Table 8. Input and output of variables
表 8. 变量的输入和移出

模型	变量已输入	变数已移除
1	加权度	LN 资产
2	PageRank	LN 负债
3	特征向量中心性	情绪 PageRank
4	紧密中心性	净利润同比增长率
5	情绪加权度	净资产同比增长率
6	情绪特征向量中心性	总资产同比增长率
7	情绪紧密中心性	
8	净资产收益率	
9	总资产报酬率	
10	权益乘数	

剔除无关变量后，对精简后的回归模型进行了变异数分析(ANOVA, Analysis of Variance)，以评估模型整体的显著性。变异数分析的结果如表 9 所示。

Table 9. Analysis of variance
表 9. 变异数分析

模型	平方和	df	平均值平方	F	显著性
1 回归	0.022	10	0.002	71.804	0.000
残差	0.035	1144	0.000		
总计	0.056	1154			

这一结果表明，经过变量筛选后的模型在统计学上仍然高度显著，说明所保留的自变量对系统性风险溢出的解释能力较强。此外，F 值较高，表明回归模型在整体上具有较强的拟合度，进一步支持了模型的有效性。

为探讨收益率复杂网络与投资者情绪网络中心性指标对系统性风险的影响，本研究以 ΔCoVaR 作为因变量，选取收益率复杂网络的加权重度、PageRank，特征向量中心性和紧密中心性，以及情绪网络的加权重度，特征向量中心性和紧密中心性作为自变量。同时，引入净资产收益率(ROE)、总资产报酬率(ROA)和权益乘数作为控制变量。基于此，我们建立了如下回归模型进行实证分析：

$$\Delta\text{CoVaR}_i = \alpha + \beta_1\text{WC}_i + \beta_2\text{PR}_i + \beta_3\text{EV}_i + \beta_4\text{CC}_i + \beta_5\text{WC_Sentiment}_i + \beta_6\text{EV_Sentiment}_i + \beta_7\text{CC_Sentiment}_i + \gamma_1\text{ROE}_i + \gamma_2\text{ROA}_i + \gamma_3\text{Equity Multiplier}_i + \varepsilon_i$$

其中， α 为常数项， β_1 至 β_7 为各中心性指标的回归系数， γ_1 至 γ_3 为控制变量的回归系数， ε_i 为误差项。为了与解释变量的频率一致，本研究将每日系统性风险数据转换为季度频率，并定义每日 ΔCoVaR_i 的季度平均值，如下所示：

$$\Delta\text{CoVaR}_{i,q} = \frac{1}{N_q} \sum_{t=1}^{N_q} \Delta\text{CoVaR}_{i,t}$$

其中， $\Delta\text{CoVaR}_{i,q}$ 表示第 i 个公司在第 q 个季度的系统性风险， N_q 为第 q 个季度内的交易天数， $\Delta\text{CoVaR}_{i,t}$ 为第 t 个交易日的系统性风险值。

实证分析中，控制变量也采用季度数据，以确保回归分析结果的准确性和一致性。估计结果如表 10 所示。

Table 10. Correlation coefficient network regression results
表 10. 相关系数网络回归结果

变量	非标准化系数	T	p 值	VIF
constant	0.014129	21.387	0.000	
WC	0.065675	22.207	0.000	7.562
PR	-0.035651	-11.319	0.000	8.548
EV	-0.017823	-8.477	0.000	7.118
CC	0.007929	3.148	0.002	4.818
WC_Sentiment	-0.012340	-6.210	0.000	3.888
EV_Sentiment	0.017205	10.244	0.000	5.035
CC_Sentiment	-0.013493	-6.466	0.000	3.655

续表

ROE	0.014620	5.847	0.000	1.378
ROA	-0.000384	-3.649	0.000	1.667
Equity Multiplier	-0.000246	-6.057	0.000	1.690

在回归分析中，方差膨胀因子(Variance Inflation Factor, VIF)是衡量多重共线性的重要指标。本研究的共线性检验结果显示，所有变量的 VIF 值均小于 10，研究中所构建的回归模型仍然具有较好的稳定性和解释能力，回归系数可以有效反映各变量对系统性风险溢出的影响。回归分析结果表明，各变量对系统性风险的影响均显著。复杂网络中，加权度(WC)对系统性风险有显著正向影响(系数 = 0.065675, p 值 = 0)，而 PageRank (PR)和特征向量中心性(EV)则表现为显著负向影响(系数分别为-0.035651 和-0.017823, p 值为 0)，说明这两种中心性较高的公司可能在风险缓释中起到作用。

投资者情绪网络中，加权度(WC_Sentiment)和紧密中心性(CC_Sentiment)显著降低系统性风险(系数分别为-0.012340 和-0.013493, p 值均为 0)，表明情绪网络中重要节点可能通过信息传递抑制风险。相反，特征向量中心性(EV_Sentiment)对系统性风险有显著正向影响(系数 = 0.017205, p 值 = 0)，说明情绪集中在某些节点时，可能加剧这些公司的系统性风险。

控制变量方面，净资产收益率(ROE)对系统性风险有正向影响(系数 = 0.014620, p 值 = 0)，而总资产报酬率(ROA)和权益乘数(Equity Multiplier)则表现为负向影响(系数分别为-0.000384 和-0.000246, p 值为 0)，表明盈利能力较高的公司承受更多风险，财务杠杆较高的公司可能有一定的风险缓冲作用。根据回归分析结果，将模型参数应用于 2022 年第四季度的数据，计算得到的 ΔCoVaR 估计值 ΔgCoVaR 与原始 ΔCoVaR 的比率结果如表 11 和表 12 所示。

Table 11. Fitting results

表 11. 拟合结果

ΔCoVaR	$\text{G}\Delta\text{CoVaR}$	$\text{G}\Delta\text{CoVaR}/\Delta\text{CoVaR}$	ΔCoVaR	$\text{G}\Delta\text{CoVaR}$	$\text{G}\Delta\text{CoVaR}/\Delta\text{CoVaR}$
0.0141923	0.016941848	1.193735229	0.012315	0.017240234	1.399937768
0.004254879	0.013352891	3.138253838	0.0186092	0.020374141	1.094842403
0.0149583	0.018511542	1.237543197	0.017369	0.018528958	1.066783253
0.0125954	0.016925365	1.343773552	0.0142449	0.016087533	1.12935389
0.0167641	0.015398788	0.918557393	0.0172166	0.01583412	0.919700749
0.015936	0.017880284	1.122005776	0.0147656	0.015464822	1.047354771
0.0197613	0.019622846	0.992993698	0.0186993	0.017922048	0.958434168
0.0197363	0.017920773	0.908010795	0.0125384	0.019120193	1.52493087
0.0191504	0.013812543	0.721266567	0.0209192	0.017279287	0.826001324
0.0208032	0.020501793	0.985511486	0.0190629	0.018537343	0.972430359
0.0146533	0.012755482	0.870485257	0.0209845	0.02007289	0.956557949
0.0173195	0.017291182	0.998364962	0.0194332	0.015413382	0.793146861
0.0146587	0.01880988	1.283188814	0.0209613	0.016496704	0.787007655
0.0152583	0.015793413	1.035070274	0.0136544	0.016342193	1.196844474
0.0162228	0.015576321	0.960149946	0.016541	0.016127131	0.974979179
0.0109401	0.016114239	1.472951695	0.0200889	0.022285882	1.109363001
0.0187416	0.016026441	0.855126641			

Table 12. Error evaluation indicators

表 12. 误差评估指标

平均绝对误差(MAE)	均方误差(MSE)	均方根误差(RMSE)
0.00253865	1.07892E-05	0.003284685

拟合分析结果进一步验证了模型的精度。通过回归系数应用于 2022 年第四季度的数据，估计值与原始比率差异较小，平均绝对误差(MAE)为 0.00253865，均方误差(MSE)为 1.07892E-05，均方根误差(RMSE)为 0.003284685，显示模型预测误差较低，拟合效果良好。尽管个别数据点存在偏差，整体误差控制在合理范围内。

5. 研究结论与政策建议

本研究基于 DCC-GJR-GARCH-CoVaR 模型，选取银行、证券、保险、信托及房地产行业的主要金融机构，并结合收益率与投资者情绪的复杂网络进行分析，并采用皮尔森、肯德尔相关系数和互信息刻画其关系。结果表明，证券与保险行业的系统性风险贡献较高，而银行、信托机构和房地产行业排名相对靠后，显示出不同金融机构在市场波动中的差异化影响。回归分析结果进一步揭示了复杂网络结构及投资者情绪对系统性风险的作用机制。收益率网络中，加权重(WC)与系统性风险正相关，PageRank (PR)和特征向量中心性(EV)表现出风险抑制效应；情绪网络中的 WC_Sentiment 和 EV_Sentiment 同样显著影响系统性风险，反映出投资者情绪的集中或分散对风险传染的作用。拟合分析显示模型稳健，误差较小(MAE = 0.00253865, MSE = 1.07892E-05, RMSE = 0.003284685)。研究揭示了金融机构在复杂网络中的不同中心性特征对系统性风险的差异化影响，为宏观审慎监管与风险防控提供了实证支持。

政策建议

基于上述研究结果，提出以下政策建议，以优化金融市场的系统性风险管理：

1. 加强对证券和保险行业的风险监测。由于证券和保险行业在系统性风险中占据较高权重，监管机构应强化对这些行业的风险监测，特别是提高资本充足率要求，并加强流动性管理，以降低风险溢出效应。

2. 区分网络结构实施差异化监管。对于在收益率复杂网络中加权重较高的机构，应加强资本和流动性监管，降低其在金融市场中的系统性风险传播作用。对于 PageRank 和特征向量中心性较高的机构，适当放宽流动性约束，以鼓励其发挥风险缓释功能。

3. 关注市场情绪对风险的影响。在情绪网络中，投资者情绪的高度集中可能加剧市场动荡。因此，应引导金融市场透明化，增强信息披露，防止市场情绪非理性集中。此外，可以通过引入市场情绪指数，动态调整宏观审慎政策，如差异化的资本监管要求。

未来研究可进一步丰富情绪数据，引入新闻情绪和社交媒体情绪等指标，并评估其对系统性风险的影响。同时，可结合更多金融子行业和动态变量，运用机器学习方法优化风险测度，提升系统性风险评估的精准性。

参考文献

- [1] Bernanke, B.S. (1983) Non-Monetary Effects of the Financial Crisis in the Propagation of the Great Depression. National Bureau of Economic Research.
- [2] Kaufman, G.G. (1996) Bank Failures, Systemic Risk, and Bank Regulation. *Cato Journal*, **16**, 17-45.
- [3] Longerstaey, J. and Spencer, M. (1996) Riskmetricstm—Technical Document. Morgan Guaranty Trust Company of New

- York.
- [4] Adrian, T. and Brunnermeier, M.K. (2011) CoVaR. National Bureau of Economic Research.
- [5] Adrian, T. and Brunnermeier, M.K. (2016) Covar. *American Economic Review*, **106**, 1705-1741. <https://doi.org/10.1257/aer.20120555>
- [6] Huang, X., Zhou, H. and Zhu, H. (2011) Systemic Risk Contributions. *Journal of Financial Services Research*, **42**, 55-83. <https://doi.org/10.1007/s10693-011-0117-8>
- [7] Karimalis, E.N. and Nomikos, N.K. (2017) Measuring Systemic Risk in the European Banking Sector: A Copula Covar Approach. *The European Journal of Finance*, **24**, 944-975. <https://doi.org/10.1080/1351847x.2017.1366350>
- [8] Bollerslev, T. (1986) Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, **31**, 307-327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- [9] Engle, R. (2002) Dynamic Conditional Correlat Ion. *Journal of Business & Economic Statistics*, **20**, 339-350. <https://doi.org/10.1198/073500102288618487>
- [10] Mantegna, R.N. (1999) Hierarchical Structure in Financial Markets. *The European Physical Journal B*, **11**, 193-197. <https://doi.org/10.1007/s100510050929>
- [11] Kritzman, M., Li, Y., Page, S. and Rigobon, R. (2011) Principal Components as a Measure of Systemic Risk. *The Journal of Portfolio Management*, **37**, 112-126. <https://doi.org/10.3905/jpm.2011.37.4.112>
- [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] Wen, S., Li, J., Huang, C. and Zhu, X. (2023) Extreme Risk Spillovers among Traditional Financial and Fintech Institutions: A Complex Network Perspective. *The Quarterly Review of Economics and Finance*, **88**, 190-202. <https://doi.org/10.1016/j.qref.2023.01.005>
- [14] Baker, M. and Wurgler, J. (2007) Investor Sentiment in the Stock Market. *Journal of Economic Perspectives*, **21**, 129-151. <https://doi.org/10.1257/jep.21.2.129>
- [15] Tetlock, P.C. (2007) Giving Content to Investor Sentiment: The Role of Media in the Stock Market. *The Journal of Finance*, **62**, 1139-1168. <https://doi.org/10.1111/j.1540-6261.2007.01232.x>
- [16] Bollen, J., Mao, H. and Zeng, X. (2011) Twitter Mood Predicts the Stock Market. *Journal of Computational Science*, **2**, 1-8. <https://doi.org/10.1016/j.jocs.2010.12.007>
- [17] Preis, T., Moat, H.S. and Stanley, H.E. (2013) Quantifying Trading Behavior in Financial Markets Using Google Trends. *Scientific Reports*, **3**, Article No. 1684. <https://doi.org/10.1038/srep01684>
- [18] Wang, G., Xiong, L., Zhu, Y., Xie, C. and Foglia, M. (2022) Multilayer Network Analysis of Investor Sentiment and Stock Returns. *Research in International Business and Finance*, **62**, Article 101707. <https://doi.org/10.1016/j.ribaf.2022.101707>
- [19] Aruoba, S.B. and Diebold, F.X. (2010) Real-Time Macroeconomic Monitoring: Real Activity, Inflation, and Interactions. *American Economic Review*, **100**, 20-24. <https://doi.org/10.1257/aer.100.2.20>
- [20] Hudson, R.S. and Gregoriou, A. (2015) Calculating and Comparing Security Returns Is Harder than You Think: A Comparison between Logarithmic and Simple Returns. *International Review of Financial Analysis*, **38**, 151-162.
- [21] Markowitz, H. (1952) Portfolio Selection. *The Journal of Finance*, **7**, 77-91. <https://doi.org/10.1111/j.1540-6261.1952.tb01525.x>
- [22] Onnela, J.-., Chakraborti, A., Kaski, K., Kertész, J. and Kanto, A. (2003) Dynamics of Market Correlations: Taxonomy and Portfolio Analysis. *Physical Review E*, **68**, Article 056110. <https://doi.org/10.1103/physreve.68.056110>
- [23] Barberis, N., Shleifer, A. and Vishny, R. (1998) A Model of Investor Sentiment. *Journal of Financial Economics*, **49**, 307-343. [https://doi.org/10.1016/s0304-405x\(98\)00027-0](https://doi.org/10.1016/s0304-405x(98)00027-0)
- [24] Brown, G.W. and Cliff, M.T. (2004) Investor Sentiment and the Near-Term Stock Market. *Journal of Empirical Finance*, **11**, 1-27. <https://doi.org/10.1016/j.jempfin.2002.12.001>
- [25] Fiedor, P. (2014) Networks in Financial Markets Based on the Mutual Information Rate. *Physical Review E*, **89**, Article 052801. <https://doi.org/10.1103/physreve.89.052801>
- [26] Tumminello, M., Aste, T., Di Matteo, T. and Mantegna, R.N. (2005) A Tool for Filtering Information in Complex Systems. *Proceedings of the National Academy of Sciences*, **102**, 10421-10426. <https://doi.org/10.1073/pnas.0500298102>
- [27] Wills, R.S. (2006) Google's Pagerank. *The Mathematical Intelligencer*, **28**, 6-11. <https://doi.org/10.1007/bf02984696>