

大维视角下的中美股市动态关联与 宏观经济环境变动*

郑挺国 叶仕奇 范小龙 张宏音

内容提要: 标本兼治、远近结合是防范化解重大金融风险的核心手段。考虑到中美两国股市存在复杂的内外部风险关联,且受到宏观经济环境变化的影响,本文提出超高维混频DCC模型,从大维复杂经济系统视角考察中美股市的风险关联。进一步延拓传统研究范式,基于短期和长期相关系数构建复杂网络,从静态到动态、全局到局部的视角分析中美股市间的风险交互效应,进而从一级行业和个股两个层面度量风险关联强度,并捕捉重要的风险关联节点。研究表明,宏观经济代理变量对个股波动的平均解释程度占比为31%,是个股波动和风险关联的重要驱动因素。相较于美国股市,我国股市波动受宏观经济环境变动的影响较小。短期来看,我国铜、铝等有色金属细分行业与美国股市关联紧密,一级行业层面的风险关联渠道则位于金融、房地产和交通运输行业。长期来看,中美股市在有色金属、金融、煤炭方面存在紧密风险关联。本研究对于厘清跨国股市风险关联机制、防范金融系统性风险具有积极意义。

关键词: 超高维混频DCC模型; 股市波动; 风险关联; 复杂网络

DOI: 10.19343/j.cnki.11-1302/c.2026.01.003

中图分类号: F831 **文献标识码:** A **文章编号:** 1002-4565(2026)01-0041-15

Dynamic Linkage between Chinese and American Stock Markets and Macroeconomic Environment Shifts from a Vast-Dimensional Perspective

Zheng Tingguo Ye Shiqi Fan Xiaolong Zhang Hongyin

Abstract: Combining symptomatic and fundamental treatment and integrating short-term and long-term perspectives are essential for mitigating major financial risks. Given the complex internal and external risk linkage between the Chinese and U.S. stock markets under changing macroeconomic conditions, this paper extends an ultra-high-dimensional DCC MIDAS model to examine risk linkage from both global and individual perspectives, across short-term and long-term horizons. Using the stock market big data, we incorporate U.S.-China economic policy uncertainty and global geopolitical risk as proxies for macroeconomic fluctuations to quantify bilateral risk linkages. Going beyond conventional approaches, we construct complex networks based on short-term and long-term correlations and apply the TMFG filtering algorithm to map them onto a low-dimensional manifold. This enables a dynamic, multi-level analysis of risk interactions, identifying key nodes and measuring risk linkage at both the sectoral and stock levels. Results show that macroeconomic proxies explain on average 31% of individual stock volatility,

*基金项目: 国家社会科学基金重大项目“大数据方法在宏观经济预测中的应用研究”(23&ZD074)。

highlighting their importance in driving volatility and risk linkage. Compared to the U.S. market, Chinese stock volatility is less sensitive to macroeconomic changes. In the short term, China's non-ferrous metal sectors (e.g. copper, aluminum) show strong connections with U.S. stocks, while key sectoral channels include finance, real estate, and transportation. In the long term, significant risk linkages exist in non-ferrous metals, finance, and coal. These findings shed light on cross-border risk transmission mechanisms and provide valuable insights for preventing systemic financial risks.

Key words: Ultra-High-Dimensional DCC MIDAS Model; Stock Market Volatility; Risk Linkage; Complex Network

一、引言与文献综述

资本市场的发展提升了金融行业在我国经济体系中的地位，亦带来潜在的金融系统性风险。保障金融市场的平稳运行对于我国经济高质量发展具有重要意义。2022年12月中央经济工作会议提出“要有效防范化解重大经济金融风险。必须坚持标本兼治、远近结合，牢牢守住不发生系统性风险底线。”2025年12月中央经济工作会议再次指出：“纵深推进全国统一大市场建设，持续防范化解重点领域风险。”^①

随着我国资本市场的逐步开放，中美两国的经济和金融市场间合作与竞争加剧。自2001年我国加入WTO以来，通过实施一系列政策，如QFII(Qualified Foreign Institutional Investor)、QDII(Qualified Domestic Institutional Investor)、港股通^②等，我国与国际金融市场的联系日益紧密，在全球经济体系中发挥着关键作用。我国发展的外部环境急剧变化，不确定难预料因素显著增多，尤其是以美国为首的西方国家对我国实施了全方位的遏制、围堵、打压，给我国发展带来前所未有的严峻挑战^③。特别是，美国对华经济政策的变化加剧了金融市场的不确定性。例如，美国硅谷银行倒闭事件引发对全球金融风险的担忧。在这种复杂的国际金融环境下，动态量化中美股市的关联性并从中识别重要风险节点，能够为防范重大金融风险提供有效实践工具。

股市动态关联的量化研究一直是金融计量和风险管理的研究热点。关于股市关联的分析和预测最早追溯到Engle(2002)提出的DCC(Dynamic Conditional Correlation)模型，该模型利用股票价格的历史信息刻画相关系数矩阵的演化路径。随着全球金融改革的逐步推进与金融市场产品的日益丰富，股市波动来源及风险关联更加复杂，对于股市波动的量化与预测更需要引入宏观经济信息，以刻画宏观经济环境变化可能带来的潜在长期影响(杨科等, 2023; 李政等, 2024)。Schwert(1989)最早开始分析股票波动与宏观经济信息之间的关系，Engle等(2013)将DCC模型和MIDAS(Mixed Data Sampling)方法相结合(以下简称DCC-MIDAS模型)，用于建立高频金融数据与低频宏观经济数据之间的联系，并揭示美国宏观经济基本面对股票市场波动率的显著长期作用。众多学者对DCC-GARCH(Generalized Autoregressive Conditional Heteroskedasticity)模型进行拓展，Asgharian等(2016)将宏观经济变量和滞后相关性同时引入长期成分中。Fang等(2017)将不同时期的经济结构作为虚拟变量加入到长期成分中进行考量。Allard等(2020)基于宏观经济变量的频率将Colacito等(2011)提出的GARCH-MIDAS模型中相关性的短期成分和长期成分进一步细分为短期成分、中

①相关网址为https://www.gov.cn/yaowen/liebiao/202512/content_7050963.htm。

②港股通是沪港股票市场交易互联互通机制的组成部分，全称为港股直通车。

③相关网址为https://www.gov.cn/xinwen/2023-03/06/content_5745092.htm。

期成分和长期成分。

除国家自身的宏观经济信息外，股市往往会因外部经济政策不确定性或地缘政治风险的增加产生较大波动。例如，2018年3月美国宣布对我国进口钢铁征税，引发我国A股钢铁行业个股下跌；2019年5月美国宣布将华为及其子公司列入“出口管制”的实体名单，我国A股芯片行业个股暴跌；2022年2月俄乌冲突爆发后，A股市场单日涨跌幅多次超过5%，呈现较强波动性；2025年4月中美贸易战升级，上证指数单日暴跌超过7%。Hu等（2018）认为美国经济政策不确定性对我国A股收益具有负向影响，Zaremba等（2022）发现各国地缘政治风险的变化对于全球新兴市场股价有显著预测作用。鉴于此，为揭示不确定性因素对中美股市动态关联的长期影响，特别是中美贸易争端、俄乌冲突等重要国际事件对于我国金融市场的输入性风险，本文在DCC-MIDAS模型中引入我国与美国的经济政策不确定性和地缘政治风险指数，利用前述宏观信息识别股市波动的长期驱动因素，从而远近结合地防范系统性金融风险，对于维护我国金融安全具有现实意义。

然而，现有研究在引入宏观经济信息以量化股市动态关联和探寻风险关联节点方面存在以下不足。首先，目前的DCC-MIDAS模型仅能反映宏观经济变量对于少数几个聚合股票指数的长期影响，却难以深入行业乃至个股层面考察宏观经济变量的长期影响。其次，随着中美两国上市公司数量逐年上升，股市中个股的异质性显著增加，直接影响金融市场的波动并加剧风险传播（Gabaix等，2003），从而产生潜在的系统性风险。而现有基于DCC-MIDAS模型的研究虽然可以考察股市的长短期相关性，但个股之间的动态关联难以被同时充分考虑。最后，现有DCC-MIDAS刻画风险关联的研究范式，往往是围绕模型参数估计或几个聚合股指的时变相关系数走势进行分析。在金融市场繁荣发展的背景下，全球金融资本总量持续上升，金融机构联系愈加紧密，金融风险呈现出多元化趋势（郑挺国等，2024ab），传统DCC-MIDAS研究方法无法直接刻画风险在股市内和股市间的复杂关联，更未能清晰、准确定位风险关联的重要节点。鉴于此，传统DCC-MIDAS模型及其对于风险关联分析的研究范式亟待改进。

关于如何刻画金融系统的风险关联强度、捕捉重要风险关联节点，现有研究已进行系列尝试。Diebold和Yilmaz（2014）基于VAR模型的广义方差分解方法构建金融风险关联网络。Barigozzi和Hallin（2017）则认为低维度金融系统的风险关联分析结论难以应用于高维金融场景。与之相比，高维视角的金融网络可以通过引入更多变量信息，避免因变量选择造成的模型设定偏误。Bardoscia等（2021）提出使用复杂网络定量分析金融体系的拓扑结构。总体而言，量化金融风险的方法丰富多样，虽能从多角度刻画股市内各行业或者各股市股指之间的风险关联，但少有研究能够深入个股视角，将高维金融系统分析与跨市场分析相结合。更鲜有研究将宏观经济信息纳入到高维股市系统分析中，度量宏观经济环境变化对跨国股市系统性风险关联的长期作用。

本文旨在将个股中蕴含的丰富信息与宏观经济相关的重要信息相结合，在大维复杂系统下考察中美股市的动态关联，刻画风险关联特征并精准捕捉重要风险关联节点，以期基于标本兼治、远近结合的思路，由全局到局部，由短期到长期，综合国内和国际两个视角，全方位监测与把控我国股市风险，为防范化解重大金融风险提供实证依据。为此，本文做出以下三点重要延拓。第一，拓展DCC-MIDAS模型至超高维情景，实现千维时间序列数据时变相关系数矩阵的快速估计，从而将刻画金融风险关联性的颗粒度由一级行业细化到个股和细分的三级行业，在保留全局性风险关联信息的基础上，精准识别局部和个股的风险波动信号。第二，将宏观信息纳入高维股市系统分析中，基于

提出的超高维DCC-MIDAS模型，从高维视角分析宏观信息对中美股市动态关联的长期影响，探究股市波动与风险关联的短期与长期驱动因素。第三，将复杂网络分析与超高维DCC-MIDAS模型相结合，构建由静态到动态、由短期到长期、由全局到局部，由个股到一级行业的高维复杂相关性网络的实证分析框架，捕捉重要的个股、行业风险关联节点，逐步刻画中美股市风险关联的总体特征和事件冲击下的动态演变规律。

二、模型设定与方法说明

大数据时代背景下，数据种类以及数据量的迅猛增长使传统DCC-MIDAS模型及其研究范式难以适用于大维复杂系统的建模与分析。本文将Colacito等（2011）提出的DCC-MIDAS模型拓展为超高维DCC-MIDAS模型，具体改进包括以下两个方面。一是将长期相关性拆分为无条件相关性均值成分和随机漂移成分。其中，无条件相关性均值成分通过Ledoit和Wolf（2020）提出的非线性收缩估计量（Nonlinear Shrinkage Estimator, NS）估计，随机漂移项成分则通过费雪转换进行刻画。二是参考相关研究（Engel等，2019；Pakel等，2021）中的复合似然方法（Composite Likelihood Method, CLM），在两步法估计的第二步估计中使用复合似然估计，解决高维场景下极大似然估计存在的计算和收敛问题。

将超高维DCC-MIDAS模型估计得到的短期、长期时变相关系数矩阵转化为距离矩阵，则可以构建短期、长期时变复杂风险关联网络。考虑到基于相关系数矩阵构建的复杂网络是全连接有权网络，本文进一步通过Massara等（2017）提出的三角最大滤波图（Triangulated Maximally Filtered Graph, TMFG）方法将高维相关系数复杂网络映射到低维流形中，从全局、局部、节点等不同视角对中美股市时变复杂风险关联网络的特征进行刻画与分析。

（一）超高维DCC-MIDAS模型建模及估计

假定 N 个资产收益率序列 $\mathbf{r}_t = (r_{1t}, \dots, r_{Nt})'$ ， r_{it} 为资产 i 在 t 时刻的收益率，根据经典DCC模型设定，假定 \mathbf{r}_t 的条件分布如下：

$$\mathbf{r}_t | \mathcal{F}_t \sim \mathbf{N}(\boldsymbol{\mu}, \mathbf{H}_t) \tag{1}$$

其中， $\boldsymbol{\mu}$ 为 \mathbf{r}_t 的无条件均值， \mathcal{F}_t 为历史信息集合，条件协方差矩阵 $\mathbf{H}_t = \mathbf{D}_t^{1/2} \mathbf{R}_t \mathbf{D}_t^{1/2}$ ， \mathbf{D}_t 为协方差矩阵的对角矩阵，即 $\mathbf{D}_t = \text{diag}(\mathbf{H}_t)$ 其对角元素是收益率序列的方差，条件相关系数矩阵 $\mathbf{R}_t = \mathbf{E}_{t-1}(\mathbf{v}_t \mathbf{v}_t' | \mathcal{F}_{t-1})$ ， $\mathbf{v}_t = \mathbf{D}_t^{-1/2}(\mathbf{r}_t - \boldsymbol{\mu})$ 。因此式（1）也可以表示为 $\mathbf{r}_t = \boldsymbol{\mu} + \mathbf{H}_t^{1/2} \mathbf{v}_t$ ， $\mathbf{v}_t \stackrel{iid}{\sim} \mathbf{N}(\mathbf{0}, \mathbf{I}_N)$ 。

基于已有研究（Engle, 2002；Colacito等，2011；Engle等，2013，2019；Ledoit和Wolf, 2020），本文提出适用于股市大数据的超高维DCC-MIDAS模型，该模型的估计为两步法估计。第一步，使用GARCH-MIDAS方法估计各个资产收益率序列的条件波动率，具体设定如下：

$$\begin{aligned} r_{it} - \mathbf{E}_{t-1}(r_{it}) &= \sqrt{\tau_{it}} g_{it} v_{it}, \quad \tau_{it} = f_{de-long}(\tau_{it}^l), \quad l = 1, \dots, L \\ \log \tau_{it}^l &= m_i + \sum_{k=1}^K \phi_k(\omega_1, \omega_2) \left(\sum_{j=1}^J \theta_j X_{j,t-k}^l \right); \quad J \geq 1 \\ g_{it} &= (1 - \alpha_i - \beta_i) + \frac{\alpha_i}{\tau_{i,t-1}} (r_{it} - \mu_i)^2 + \beta_i g_{i,t-1} \\ \phi_k(\omega_1, \omega_2) &= \frac{(k/K)^{\omega_1-1} (1-k/K)^{\omega_2-1}}{\sum_{j=1}^K (j/K)^{\omega_1-1} (1-j/K)^{\omega_2-1}}; \quad k = 1, \dots, K \end{aligned} \tag{2}$$

其中， τ_{it}^l 是第 i 条时间序列的长期波动成分，可以是月度频率、季度频率或半年度的低频率数据。 m_i

为 τ_{it}^l 更新过程中的均值参数, ω_1, ω_2 为控制 MIDAS 滤波形式的形状参数, $X_{j,t-k}^l$ 为解释长期波动变化的外生变量, θ_j 为外生变量的影响系数。式 (2) 通过 $\phi_k(\cdot)$ (MIDAS 滤波) 将已实现波动率或低频宏观信息转化为长期成分, 对最近的已实现波动率或低频宏观经济变量赋予较大的权重。L 是对应低频宏观经济变量的频数, 即一年包括 4 个季度或 12 个月度宏观经济变量观察值。K 表示低频的滞后长度。E_t(·) 是基于 t 交易日的条件期望算子, g_{it} 是第 i 条时间序列的条件波动率的短期成分, 假设其服从 GARCH(1,1) 过程。α_i 和 β_i 均为控制 GARCH(1,1) 过程的待估模型参数。

在计算长期成分时, 采用常用的固定窗口法^①, 通过转化函数 $f_{de-long}(\cdot)$ 将 τ_{it}^l 转换为与 r_{it} 同频的 τ_{it}° , 并令月度或季度内 τ_{it} 不发生变化。当 J=1, 即仅考虑一个宏观变量时, 式 (1) 模型设定等价于 Fang 等 (2017) 的模型设定。总之, 第一步估计通过 GARCH-MIDAS 模型将宏观变量信息 X_t^l 加入到条件波动率的长期成分 τ_t^l 的刻画中, 进而与短期成分一起计算时间序列 k 的标准化残差 v_{kt} 。另外, 本文考虑 J>1 的情况, 将多个宏观经济信息变量引入到条件方差的长期成分刻画中。

基于 Conrad 和 Loch (2015) 的研究, 本文计算各方程的方差比 (Variance Ratio, VR) 以反映宏观经济变量对于股票条件波动的解释强度。GARCH-MIDAS 模型中的方差比定义为对数化的长期成分的样本方差 $\text{var}(\log(\tau_t))$ 与对数化的总成分样本方差 $\text{var}(\log(\tau_t g_{it}))$ 占比, 即

$$VR_t = \frac{\text{var}(\log(\tau_t))}{\text{var}(\log(\tau_t g_{it}))} = \frac{\text{var}(\log(\tau_t))}{\text{var}(\log(\tau_t) + \log(g_{it}))}。其中, VR_t \text{ 取值范围在 } (0,1) \text{ 之间, } VR_t \text{ 越大表明长期}$$

成分对于股票波动的解释力度越大, 即宏观信息对于股票波动的作用越强。第二步, 又称 DCC 步估计。该步估计基于第一步估计得到的标准化残差 v_t , 对个股之间的高维短期、长期相关系数矩阵 R_t 和 \bar{R}_t 进行估计, 从而借助高维相关系数矩阵, 将高维 DCC-MIDAS 模型、复杂网络构建与分析方法进行有机结合。具体而言, 超高维 DCC-MIDAS 模型中, 短期相关系数矩阵 R_t 通过对拟相关系数矩阵 Q_t 进行标准化处理得到, 即 $R_t = \text{diag}(Q_t^{-1/2}) Q_t \text{diag}(Q_t^{-1/2})$ 。因此对于 R_t 的估计等价于对 Q_t 的估计, 这也是传统 DCC-MIDAS 模型在进行高维延拓上的难点。本文分别解决了高维情形下第二步估计中中短期成分的设定问题、宏观经济信息的引入问题与模型参数估计问题, 从而实现了超高维 DCC-MIDAS 准确、迅速的估计。

首先给出对于拟时变相关系数矩阵 Q_t 的设定, 如下所示:

$$Q_t = (1-a-b)(C + \Xi_t) + a v_{t-1} v_{t-1}' + b Q_{t-1} \quad (3)$$

其中, $\Xi_t = f_{de-long}(\Xi_t^l)$, $\Xi_t^l = \frac{\exp(2\mathbf{T}_t^l) - 1}{\exp(2\mathbf{T}_t^l) + 1}$, $\mathbf{T}_t^l = \sum_{k=1}^K \theta_1^c \Phi_k(1, \underline{\omega}_{r1}) \odot \tilde{C}_{t-k}^l + \sum_{k=1}^K \sum_{j=1}^J \theta_{j+1} \Phi_k(1, \underline{\omega}_{r,j+1}) \odot \tilde{X}_{j,t-k}^l$ 。

\mathbf{T}_t^l 为控制 Ξ_t^l 变化的中间变量, $\underline{\omega}_{r1}$ 为 \mathbf{T}_t^l 更新过程中控制 MIDAS 滤波形式的形状参数。 $\Phi_k(\underline{\omega}_r) = \phi_k(\underline{\omega}_r) u'$, $k=1, \dots, K$, 其中 u 为 N 乘 1 维的全为 1 的向量, $\phi_k(\cdot)$ 为式 (2) 中定义的 MIDAS 滤波。

$C_t^l = (D_t^l)^{-\frac{1}{2}} \left(\sum_{k=t-N^l}^t v_k v_k' \right) (D_t^l)^{-\frac{1}{2}}$, $[D_t^l]_{ii} = \sum_{k=t-N^l}^t (v_{ik})^2$, $\tilde{C}_t^l = f_{de-mean}(C_t^l)$, $\tilde{X}_t^l = f_{de-mean}(X_t^l)$ 。

$f_{de-mean}(\cdot)$ 为去均值化算子^③, N^l 为月度或季度对应的交易日天数, \tilde{C}_t^l 、 \tilde{X}_t^l 分别为去均值后的低频相关系数矩阵与外生宏观经济变量, θ_1^c 和 θ_{j+1} 分别为 θ_{j+1} 对应的影响系数。

① 本文亦考虑了滚动窗口的长期成分估计法, 结果稳健。

② 转化函数将月度的低频长期成分通过填补法填补为日度的高频时间序列, 得到的高频时间序列每个月的值在当月内保持不变, 与低频长期成分在该月的值相对应。

③ 去均值化算子对于矩阵中的每一个元素, 减去其在时间维度上的均值。去均值后的相关系数矩阵对角元素为 0。

Colacito等（2011）提出的DCC-MIDAS模型在DCC步骤中并未将低频宏观经济变量信息引入到长期相关成分中。相关研究（Asgharian等，2016；Fang等，2017）虽将低频宏观信息、经济结构信息引入到长期相关性中，但考虑的DCC-MIDAS模型中截距项含有 $N(N+1)/2$ 个待估参数，因此仅能考虑低维少数几个变量下的情况。本文根据均值回归的基本思想，将长期相关性拆分为均值成分和随机漂移成分，成功解决上述问题。具体而言， $\mathbf{Q}_t - \bar{\mathbf{R}}_t = a(\mathbf{v}_{t-1}\mathbf{v}'_{t-1} - \bar{\mathbf{R}}_t) + b(\mathbf{Q}_{t-1} - \bar{\mathbf{R}}_t)$ ， $\bar{\mathbf{R}}_t = \mathbf{C} + \boldsymbol{\Xi}_t$ 。其中， $\bar{\mathbf{R}}_t$ 为低频的时变长期相关成分。本文进一步将 $\bar{\mathbf{R}}_t$ 拆分为两部分，一部分为标准化残差 \mathbf{v}_{t-1} 造成的偏离，另一部分为 \mathbf{Q}_{t-1} 所造成的偏离。因此，长期相关性 $\bar{\mathbf{R}}_t$ 来源主要包括无条件相关系数成分 \mathbf{C} 和长期随机漂移成分 $\boldsymbol{\Xi}_t$ ， $\boldsymbol{\Xi}_t$ 围绕长期相关性的基本面 \mathbf{C} 扰动，长期随机漂移成分 $\boldsymbol{\Xi}_t$ 与历史相关系数 \mathbf{C}'_t 和低频宏观经济变量 \mathbf{X}'_t 相关。

进一步地，借鉴Perego和Vermeulen（2016）的研究，将长期成分 \mathbf{T}'_t 通过费雪转换映射到 $[-1,1]$ 边界中，对于量纲较大的低频宏观经济变量 $\check{\mathbf{X}}'_t$ ，可先对其进行对数化处理，降低异常值对于长期随机漂移成分的影响。借鉴已有的研究将无条件相关系数矩阵 \mathbf{C} 作为长期相关性的均值成分，即为长期相关性的基本面（Engle等，2019；Ledoit和Wolf；2020）。另外，本文将 $\boldsymbol{\Xi}'_t$ 作为长期相关随机扰动成分。当 $\boldsymbol{\Xi}'_t = 0$ 时，Engle等（2019）所提出的DCC-NL模型设定为超高维DCC-MIDAS模型的一个特殊形式； $\theta_i = 0$ 时，长期随机漂移相关性则全部来源于宏观信息 \mathbf{X}'_t 。超高维DCC-MIDAS模型将时间序列 i 和时间序列 j 之间的历史相关性 \mathbf{C}'_t 和宏观经济信息 \mathbf{X}'_t 引入到长期成分相关性中，从而估计得到月度的高维长期时变相关性矩阵 $\bar{\mathbf{R}}_t$ 。

最后，需讨论超高维DCC-MIDAS模型的识别问题。具体而言，倘若对短期相关系数矩阵 \mathbf{R}_t 的拟相关系数矩阵 \mathbf{Q}_t 两边同时乘以一个对角阵，即定义 $\bar{\mathbf{Q}}_t = \mathbf{Z}\mathbf{Q}_t\mathbf{Z}$ ，那么 $\mathbf{R}_t = \text{diag}(\mathbf{Q}_t^{-1/2})\mathbf{Q}_t\text{diag}(\mathbf{Q}_t^{-1/2}) = \text{diag}(\bar{\mathbf{Q}}_t^{-1/2})\bar{\mathbf{Q}}_t\text{diag}(\bar{\mathbf{Q}}_t^{-1/2})$ 。从而导致 \mathbf{R}_t 不可识别。本文对于短期拟相关系数矩阵 \mathbf{Q}_t 的更新路径设定能够从两个方面解决上述识别问题。首先，对于第二步估计而言， $\mathbf{v}_t = \mathbf{D}_t^{-1/2}(\mathbf{r}_t - \boldsymbol{\mu})$ 是由第一步估计得到的预先给定（Pre-Determined）的变量；其次，式（3）的设定下，均值成分 $\mathbf{C} + \boldsymbol{\Xi}_t$ 的对角恒为1。这意味着，倘若将式（3）的左右两端同时左乘和右乘 \mathbf{Z} ，会破坏 $\mathbf{C} + \boldsymbol{\Xi}_t$ 和 $\mathbf{v}_{t-1}\mathbf{v}'_{t-1}$ 的结构，从而使得变换前后的模型，尤其是 \mathbf{Q}_t 的更新过程不完全等价，因此解决了识别问题。

需要注意的是，本文提出的超高维DCC-MIDAS模型设定可以应用于大维复杂金融系统的估计问题，并分别提取短期和长期的时变相关系数矩阵。然而，当金融系统维度非常高时，仍有两个问题亟需解决。第一， N 很大时，对应无条件相关系数矩阵 \mathbf{C} 会存在偏差，进而影响模型的估计结果。为解决样本协方差矩阵的估计偏差问题，引入Ledoit和Wolf（2012，2020）提出并延拓的解析形式非线性收缩估计量（Nonlinear Shrinkage Estimator, NSE）^①。第二，模型极大似然估计的可行性问题。本文使用两步法估计超高维DCC-MIDAS模型的未知模型参数，其似然值（的相反数）计算如下：

$$\begin{aligned}
 QL(\boldsymbol{\lambda}, \boldsymbol{\theta}) &= \frac{1}{2} \sum_{t=1}^T (n \log 2\pi + \log |H_t| + \mathbf{r}'_t H_t \mathbf{r}_t) \\
 &= \underbrace{\frac{1}{2} \sum_{t=1}^T (n \log 2\pi + \log |\mathbf{D}_t| + \mathbf{r}'_t \mathbf{D}_t^{-1} \mathbf{r}_t)}_{QL_1(\boldsymbol{\lambda})} + \underbrace{\frac{1}{2} \sum_{t=1}^T (\log |\mathbf{R}_t| + \mathbf{v}'_t \mathbf{R}_t^{-1} \mathbf{v}_t - \mathbf{v}'_t \mathbf{v}_t)}_{QL_2(\boldsymbol{\lambda}, \boldsymbol{\theta})}
 \end{aligned} \tag{4}$$

式（4）将似然函数 $QL(\boldsymbol{\lambda}, \boldsymbol{\theta})$ 拆分为 $QL_1(\boldsymbol{\lambda})$ 和 $QL_2(\boldsymbol{\lambda}, \boldsymbol{\theta})$ 。第一步估计中，设置GARCH-MIDAS模型参数 $\boldsymbol{\lambda} \equiv [(\alpha_i, \beta_i, m_i, \omega_i, \theta_i), i=1, \dots, N]'$ ，其中 $\omega_i = (\omega_{i1}, \dots, \omega_{iJ})'$ ， $\theta_i = (\theta_{i1}, \dots, \theta_{iJ})'$ ，由于估计的是每条方程的条件波动率，最小化 $QL_1(\boldsymbol{\lambda})$ 等价于对每条收益率序列逐条地进行极大似然估计。第二步估

①因篇幅所限，收缩估计量以附录A（一）展示，见《统计研究》网站所列附件。下同。

计设置超高维DCC-MIDAS模型参数 $\theta \equiv (a, b, \Phi')$ ，直接使用极大似然估计最小化 $QL_2(\lambda, \theta)$ 以得到 θ 的似然成本过高，基本无法估计超过几十个变量的模型，且迭代估计在高维情况下基本无法收敛。

为解决第二步估计中未知的模型参数的估计问题，本文结合Engle等（2019）和Pakel等（2021）提出的成对极大复合似然（2MCLE）和连续成对极大复合似然（2MSCLE）方法，在降低计算成本的同时实现高维情况下模型参数的准确估计。极大复合似然估计法通过将样本拆分为数份低维子样本，利用子样本拟合模型，并对计算得到的似然进行组合加总作为全样本似然的近似，进而最大化全样本似然的近似，并将所得的模型参数估计值作为全样本模型参数的估计值。参考Engle等（2019）和Pakel等（2021）将DCC-GARCH模型推广到高维系统中的做法，本文采用两两配对的方法获取低维度时间序列组合^①。

（二）复杂网络构建与分析

本文将基于DCC-MIDAS模型第二步估计中得到的时变短期、长期相关系数矩阵分别构建短期和长期风险关联的复杂网络，并利用复杂网络分析法对短期与长期风险关联结构进行刻画。通过度量中美股市间的风险关联强度与网络拓扑特征，识别关键风险节点及其传导链条，从而帮助识别潜在风险传导路径。一个复杂网络 $G = (V, E, W)$ 由节点 V 、边 E 和权重矩阵 W 构成。假设 G 包含 N 个不同的节点 $V = \{1, 2, \dots, N\}$ ，那么 E 中最多可能存在 $N(N-1)$ 条连边。倘若将 G 中的节点划分为 K 个不同的社群，则节点集合可以表示为 $V = \{V_1, V_2, \dots, V_K\}$ 。其中，第 i 个社区共有 n_i 个节点，即 $|V_i| = n_i$ 。假设 $\sum_{i=1}^K n_i = M$ ，则此时 $E \subset V \times V$ ，复杂网络 G 最多存在 $M(M-1)$ 条连边。若节点 i 与节点 j 之间不存在连边， $[E]_{ij} = 0$ ，否则 $[E]_{ij} \neq 0$ ； $[W]_{ij}$ 是复杂网络 G 中节点 i 与节点 j 之间的权重值，代表连边的相对重要性。

复杂网络 G 按照边的方向可以被分为有向网络与无向网络，按照边的权重是否有差别可以分为有权网络和无权网络，按照节点间是否都有连线又可以分为部分连接或全连接网络。复杂网络 G 的另一种等价表示为邻接矩阵 A ，其对角元素为0，且非对角元素非负，代表节点之间连接的强度。例如，格兰杰因果二元检验构造的复杂网络为0-1网络，其邻接矩阵 A 所包含的元素仅为0或1，即 $[A]_{ij} \in \{0, 1\}$ 。Brownless等（2022）通过广义随机区块模型（Generalized Stochastic Block Model, GSBM）构建偏自相关系数网络，其邻接矩阵的元素介于0到1之间， $[A]_{ij}$ 可以反映出节点 i 和节点 j 之间的关联强度。

直观上看，本文基于相关系数矩阵构建的复杂网络属于无向有权全连接网络。然而，相关系数矩阵不等价于复杂网络中的邻接矩阵 A ，在构建与分析复杂网络上，还需要解决以下几个问题。

首先，相关系数矩阵中参数可能为负数，这与邻接矩阵 A 中非对角元素的非负设定相冲突。为此，本文基于欧阳红兵和刘晓东（2014）的做法，将相关系数转化为“距离”度量，具体计算方法为 $d_{ij} = \sqrt{(1 - \rho_{ij})/2}$ ； $A = [d_{ij}]$ 。

其次，由于相关系数矩阵构建的复杂网络为全连接网络，即每个节点都与其他 $N-1$ 个节点相连接，因而共有 $E(N) = \frac{N(N-1)}{2} = O(N^2)$ 条连边。随着网络节点数目的增加，连边数 $E(N)$ 作为节点数 N 的函数呈平方级增长。如此多的连边将对复杂网络的可视化分析产生影响，因此有必要对复杂网络的连边进行过滤或简化。本文采用Massara等（2017）最新提出的TMFG滤波算法，将相关系数复杂金融网络映射到低维流形中。

^①因篇幅所限，似然函数具体表示以附录A（二）展示。

最后,相较于现有文献分析静态网络,本文在不同时点均可以基于长、短期相关系数矩阵构建复杂网络。因此,需要将长、短期相关性的动态特征与现有复杂网络的指标分析法结合在一起,从动态网络视角分析不同时期不同行业之间的风险传递。具体而言,本文考虑的复杂网络统计特征包括全局网络特征、局部网络特征和节点特征^①。节点特征反映单个节点在复杂网络中发挥的作用,常见指标包含度(Degree)、特征向量中心度(Eigenvector Centrality)等。节点的度越高,表明与其他节点之间的相关性越强,其受到冲击产生的风险可能通过相关关系向其他节点传导,从而在股市关联网络中具有更为明显的风险传导作用,系统重要性相对更强。局部网络特征帮助识别复杂网络中的局部集群结构,揭示局部网络结构与节点间的关系。本文通过Song等(2012)提出的DBHT(Direct Bubble Hierarchical Tree)算法,将相关系数矩阵和距离矩阵分别作为相似性矩阵(Similarity Matrix)和非相似性矩阵(Dissimilarity Matrix),对节点进行聚类。通过识别局部集群结构,能够从中观层面将中美股市中的所有个股(行业)划分至不同类别,识别市场中的风险集中区域,并作为全局视角和节点视角之间的过渡,帮助实施差异化和针对性的风险识别与防控。全局网络特征帮助提炼复杂网络中的整体结构信息,本文使用同化率和模块度刻画中美股市关联网络的整体状态和事件冲击下的动态变化特征。其中,同化率可以帮助识别市场中的集中性或分散性风险,其侧重于考察网络中具有相似特征的节点是否更倾向于互相连接。模块度是衡量复杂网络中社区结构区分程度的指标,在本文中用于刻画中美股市之间的差异性。

(三) 数据处理

为更加精准地识别股市波动所传递的风险信号,本文以个股收益率为研究对象,构建超高维DCC-MIDAS模型。具体而言,本文以美国证券交易所时间为基准选取申万三级行业股票指数和标普500成分股^②,股指或个股的日度收益率计算为 $r_{it} = \log(p_{it} / p_{it-1}) \times 100$ 。其中, p_{it} 为股票或股指的收盘价序列, r_{it} 为股票或股指的收益率序列。申万三级行业股票指数来源于Wind金融终端,共274支三级行业股指,标准普尔(S&P)500成分股来源于英为财经(Investing)^③,共计483支成分股。交易日日期以美国证券交易所为准。因此,原始数据为757条收益率序列,时间跨度为2007年7月1日至2022年8月31日,共计3819个交易日。本文首先对原始股票数据进行系列处理,解决中美节假日以及股票停牌带来的数据缺失问题。然后,基于已有研究(Fang等,2017; Yu和Huang,2021; Li等,2024)的做法,本文选取中国经济政策不确定性(EPU)、美国经济政策不确定性指标和全球地缘政治风险指标(Geopolitical Risk, GPR),分别代表中国、美国宏观经济政策环境的变化,以及全球宏观政治经济环境状况,时间跨度为2004年7月至2022年8月,共218个观察值^④。

三、实证结果分析

本部分首先从传统视角对超高维DCC-MIDAS模型两步法估计结果进行分析,考察宏观信息对中美股市波动的贡献程度,以及中美股市总体相关性的短期和长期动态趋势。其次从复杂网络视角,基于DCC-MIDAS模型估计得到短期和长期时变相关系数矩阵,构建中美股市风险关联的时变复杂网络,进一步借助复杂网络的全局、局部和节点统计特征刻画中美股市风险关联结构、识别重要风险

^①因篇幅所限,复杂网络统计特征介绍以附录A(三)展示。

^②因篇幅所限,数据选取与处理方法以附录B(一)展示。

^③英为财经相关网址为<https://cn.investing.com/>。

^④因篇幅所限,数据描述性统计与波动性分析以附录B(二)展示。低频变量的时间窗口设定较高频变量提前三年,用于在MIDAS框架下提取长期波动成分。

关联节点。

(一) 超高维DCC-MIDAS模型估计结果分析^①

本文分别考察中美股市大数据下超高维DCC-MIDAS两步法估计的结果，并从模型参数估计结果和时变长、短期波动率及相关系数走势两方面考察中美股市内部与股市间的动态关联。首先考察超高维DCC-MIDAS模型第一步的估计结果，其GARCH-MIDAS模型的长期成分设定为

$$\log \tau_t^l = m + \sum_{k=1}^K [\theta_1 \phi_k(1, \omega_1) X_{t-k}^{EPU} + \theta_2 \phi_k(1, \omega_2) Y_{t-k}^{EPU} + \theta_3 \phi_k(1, \omega_3) GPR_{t-k}^{global}]。$$

本文基于Conrad和Loch（2015）和宏观信息变量的选取，设定 $J=3$ ，即在GARCH-MIDAS模型中同时加入中美宏观经济变量。其中， X_t 为我国宏观经济变量， Y_t 为美国宏观经济变量。这意味着，对于每一个股指或个股收益率序列，第一步中需要估计9个模型参数。此外，参考Engle等（2013）和Fang等（2017）的研究，本文选取 $K=36$ 作为宏观经济变量的滞后期数，即滞后三年宏观经济变量，以刻画波动率中的长期成分^②。最后，在GARCH-MIDAS模型中设置单参数Beta多项式函数，在保证模型灵活性的同时提高参数估计的数值效率（周开国等，2021）。

进一步地，计算每个方程拟合结果的方差比（VR），以评估含有宏观经济变量信息的长期成分 τ_t^l 对于中美股市中行业和个股条件波动率的贡献程度。标普500股票波动中的长期成分方差比的均值相较于申万三级行业股指更大，且方差比的尾部分布效应更加明显。这表明相比于我国股票市场，宏观信息的作用在美国股票市场中的异质性更强。进一步地，中美整体方差比的均值约为31%，申万三级行业股指方差比的均值约为25%，这意味着宏观经济政策变化和地缘政治风险对于我国股市波动的长期影响能力相较于美股而言较弱。

以下考察超高维DCC-MIDAS模型第二步的估计结果，长期关联成分 T_t^l 设定如下：

$$T_t^l = \sum_{k=1}^{L_c} [\theta_1^c \Phi_k(\omega_{r1}) \odot \tilde{C}_{t-k}^l + \theta_2^c \Phi_k(\omega_{r2}) \odot \tilde{X}_{t-k}^{EPU} + \theta_3^c \Phi_k(\omega_{r3}) \odot \tilde{Y}_{t-k}^{EPU} + \theta_4^c \Phi_k(\omega_{r4}) \odot GPR_{t-k}^{global}] \quad (5)$$

同第一步估计类似，选取 $J=3$ ，即将3个宏观变量引入到长期相关成分的刻画之中，考察宏观信息在长期波动关联形成机制中的作用。为降低第二步中参数估计个数和保证MIDAS中的Beta系数 $\phi_k(\cdot)$ 单调递减，在DCC步估计中亦使用单变量Beta多项式函数。超高维DCC-MIDAS模型在第二步中需要估计20个参数。

式（5）中 $\theta^c = (\theta_1^c, \theta_{2,3}^c, \theta_4^c)'$ 分别为历史相关系数、中美经济政策不确定性和全球地缘政治风险的待估参数。相关性的长期成分 T_t^l 是超高维DCC-MIDAS模型DCC步估计中长期相关性的核心所在，可以基于 T_t^l 中的模型参数分析宏观经济信息对于股市风险关联的影响。与GARCH-MIDAS中波动长期成分相似， θ^c 的正负可以揭露宏观经济信息对于股市长期相关性是否具有逆周期性影响。

图1（a）展示了本文提出的HD-DCC-MIDAS模型与Engle等（2019）提出的DCC-NL模型中DCC步估计得到的平均短期相关系数对比图。其中，点线为DCC-NL模型估计结果，实线为HD-DCC-MIDAS模型的估计结果。需要注意的是，本文提出的模型在不引入宏观经济信息、且不考虑漂移项 Ξ_t^l 情况下，其模型设定应该与DCC-NL完全等价，虚线为在此设定下的模型估计结果，记为DCC-NL（Python）。图1（a）结果表明，首先，基于本文提出模型的特殊形式估计结果（虚线）与Engle等（2019）中DCC-NL的估计结果（点线）几乎重合，充分表明超高维DCC-MIDAS在代码上的稳健性。其次，

①因篇幅所限，部分模型参数估计结果和相关分析以附录C（一）展示。

②随着滞后阶数K的增加，长期成分所包含的信息也将随之增加，参数估计结果趋于稳定。因篇幅所限，滞后阶数K的选择及相关稳健性分析以附录A（四）展示。

超高维DCC-MIDAS模型估计结果与DCC-NL的估计结果走势一致，超高维DCC-MIDAS模型由于引入宏观经济信息，在重大事件冲击下的平均短期相关系数与DCC-NL模型存在差异，即超高维DCC-MIDAS模型的平均短期相关系数达到峰值后下降更快。此外，2010年欧洲债务危机、2015年我国股市异常波动、2018年中美贸易摩擦、2020年突发公共卫生事件新冠疫情发生后，短期相关系数都急剧上升，表明此时中美股市的金融风险不容小视。此外，本文在数值模拟层面验证了所提出的超高维DCC-MIDAS模型在模型估计的速度以及参数估计的收敛性，并且基于实际数据验证了高频成分和高维DCC-GARCH模型具有可比性^①，但尚未从理论上严格证明模型的统计性质。为此，本文将超高维DCC-MIDAS模型的统计推断问题列为未来持续深入挖掘的研究工作。

图1(b)为超高维DCC-MIDAS模型DCC步估计中对角线以及非对角线位置的平均短期相关系数 (Mean of Short-Term Correlation, MSC) 走势。虽然我国股市的短期相关性总体水平高于美国股市，但在面临重大事件冲击时，我国股市相关性的变动幅度相对较小。具体而言，2011年4月至10月美股受欧洲债务危机、美国债务危机影响，标普500最大跌幅达20%，此时美国短期相关系数出现突然上升的现象，然而我国MSC上升趋势相对平缓。2015年6月我国股市异常波动后，我国MSC缓慢上升，2015年8月中美非对角线MSC、美国MSC出现尖峰，中美非对角线MSC领先美国MSC。2018年中美经贸摩擦期间，我国MSC缓慢上升后下降，中美非对角线MSC、美国MSC出现多个尖峰。2020年全球经济受新冠疫情影响，中美MSC均出现剧烈上涨，此时美国MSC的上升幅度远高于我国。

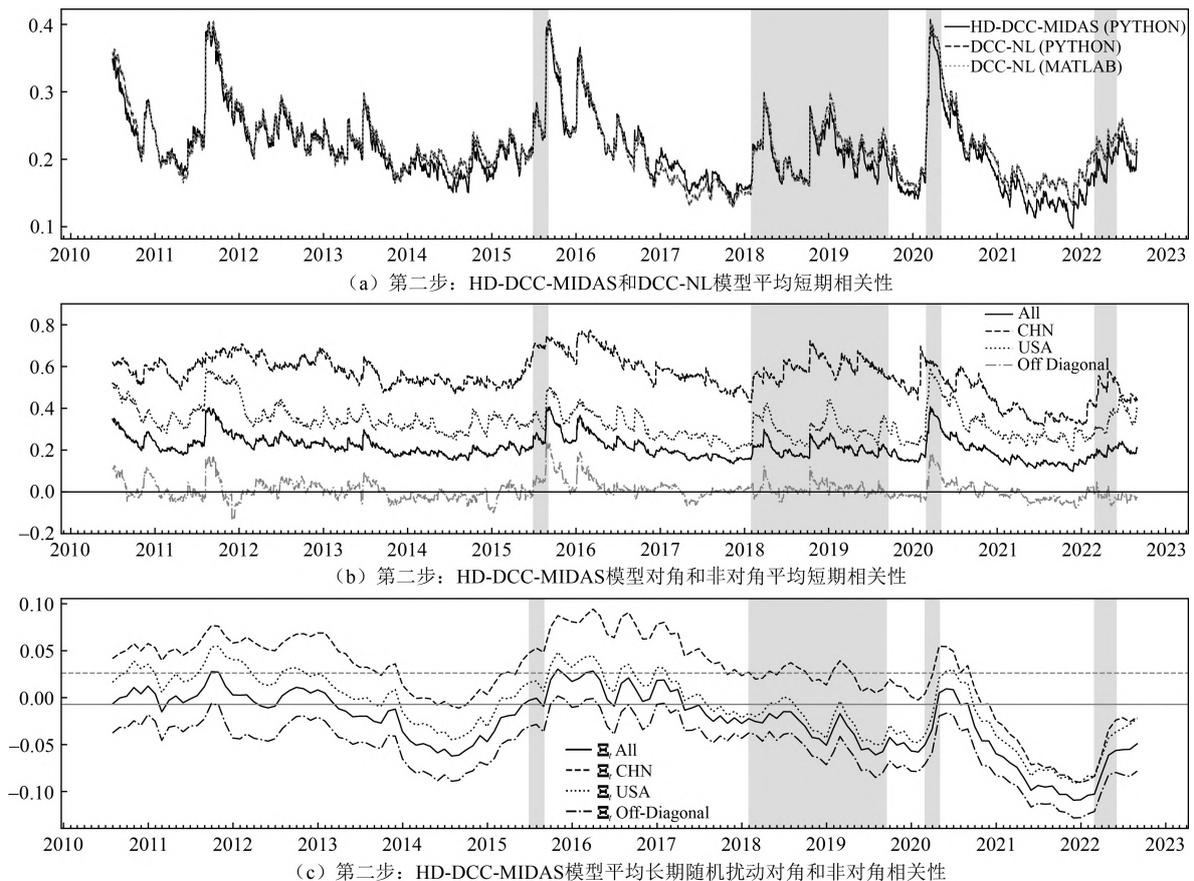


图1 中美股市短期平均相关系数和长期漂移成分相关系数走势图

①因篇幅所限，相关讨论以附录A（五）展示。

图1(c)为长期相关性的随机扰动成分的走势,虚线为中美两国随机扰动成分的均值。结果表明,中美两国的随机扰动成分走势基本一致,我国股市的长期相关性随机扰动围绕0.02附近波动,美国的长期相关性随机扰动围绕0附近波动。2020年全球新冠疫情后,随机扰动成分长期处于均值之下,这与Dietrich等(2020)的研究中关于新冠疫情导致经济衰退的发现相吻合。

(二) 复杂网络分析

传统DCC-MIDAS模型的研究范式侧重于分析参数估计与时变相关系数趋势结果,但在捕捉重要风险关联节点方面存在局限。鉴于此,本文通过超高维DCC-MIDAS模型第二步估计得到的短期和长期相关系数矩阵构建复杂网络,并使用TMFG算法对复杂网络进行过滤,筛选出相对重要的节点和连边。进一步地,本文从短期到长期、静态到动态、全局到局部的视角分析复杂网络,以量化重大事件冲击对于复杂网络特征的影响。此外,本文进一步将个股和三级行业聚合至一级行业^①,构建中美股市的一级行业风险关联网络,由点及面刻画中美股市的总体行业层面关联特征。

1. 短期相关性网络分析^②。

图2展示了个股和一级行业视角的短期静态相关性网络,网络通过DBHT连边进行局部聚类,不同模块之间使用虚线连接。首先考察个股视角的短期相关性网络。如图2(a)所示,总体网络区分为5个模块。其中,我国股市的大部分三级行业均处于模块I,小部分与标普500成分股共同处于模块II;标普500成分股则分布于4个模块,以模块II为主,包含工业、金融、房地产、石油等行业的个股;模块III主要包含医疗保健行业个股;模块IV主要包含科技新材料行业个股;模块V主要包含能源电力和生活消费行业个股。可见,相比于我国股市聚集在模块内部,美国股市个股体现出显著分化的现象,可能由于美国资本市场在市场多样性、信息效率、资本流动性等方面相对更为成熟,能够较为有效地分散风险和反映市场预期。此外,处于模块II中的我国股市三级行业是中美股市关联的重要节点,其包括C32(850551.SI,铝)、C33(850552.SI,铜)、C34(850553.SI,铅锌)、C29(850442,板材)和C213(859511,动力煤)等有色金属、钢铁、煤炭行业,并与标普500中的A229(FCX,铜企业)、A204(NUE,钢铁企业)直接相连。

其次,从行业层面探究中美股市关联特征。将个股和三级行业聚合至一级行业,得到的短期静态相关性网络,如图2(b)所示。可以发现,一级行业网络总体被划分为4个模块。其中,我国股市一级行业被划分至模块A和模块B,美国股市一级行业则在模块C和模块D中。与个股视角结果不同,在一级行业视角下,我国股市中的房地产、银行和非银金融行业成为连接中美股市的一级行业桥梁,共同组成模块B,并与美国股市中的能源、材料、工业行业存在密切的关联性。我国股市中的银行业和美国股市中的能源行业与对方股市的连线数目最多,因此是中美股市关联纽带中最为关键的一级行业节点。这意味着,在防范系统性金融风险时,需要兼具国际视野,实时监测美国能源市场对于我国金融、房地产行业的风险传导,同时重点关注美国材料、工业行业运行状况对于我国银行业可能产生的冲击。

最后,进入一级行业的节点视角,分析各一级行业在中美股市短期时变相关性网络中的作用。本文绘制了网络中一级行业度中心度热力图,时间频率为日度,时间跨度为2010年7月至2022年8月。结果表明,我国股市中的基础化工、机械设备、美国股市中的工业等一级行业长期处于短期相关性

^①本文采用中美股市一级行业分类标准为申万一级行业2021版(SWI2021)和全球行业分类标准(Global Industry Classification Standard, GICS)。因篇幅所限,中美股市一级行业分类详细信息以附表B.4展示,高维网络聚合方法以附录A(六)展示。

^②因篇幅所限,复杂网络分析与可视化结果以附录C(二)展示。

网络的中心地位。在2020年新冠疫情期间，我国股市网络中的轻工制造、房地产、电力设备行业的度中心度明显提升，交通运输行业的度中心度明显下降。这说明新冠疫情对交通运输行业的冲击减弱了其在股市中与其他行业之间的关联性；美国股市中工业的度中心度排名先下降后上升；机械设备行业一直处于我国股市网络中的中心位置；2017年3月去产能改革目标提出后，轻工制造行业逐渐取代基础化工行业在我国股市网络中的中心位置；工业一直处于美国股市网络中的核心位置，同时非必需消费行业也是美国股市中的重要节点。

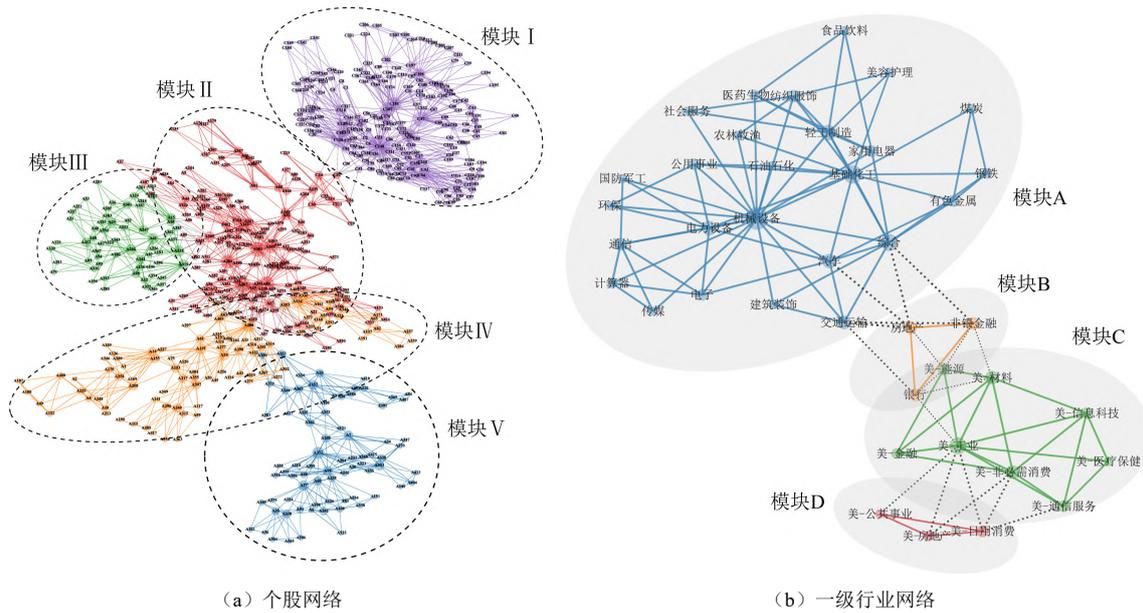


图2 中美股市个股与一级行业平均静态网络

2.长期相关性网络分析。

图3展示了长期时变相关性网络的模块度、同化率指标，时间跨度为2010年7月至2022年8月。在长期关联网络中，中美股市之间的模块度约为0.46，并在0.005范围内波动，表明中美股市的三级行业和个股之间总体区分度较为稳定。在欧债危机、中美经贸摩擦和新冠疫情，中美股市长期相关性水平均出现大幅上涨时期，二者之间的模块度下降，体现出中美股市的较强共振性，特别是在新冠疫情期间模块度的下降幅度最大。在2015年我国股市异常波动和2022年俄乌冲突期间，模块度存在一定上升趋势，表明此时中美股市对于冲击的反应存在异质性。此外，对于同化率指标，中美股市整体同化率在样本区间内始终为负，呈现异配性，即度较大的节点倾向与度较小节点相连，风险传导结构较为分散。然而，中美股市内部的同化率显著为正，呈现强强联合的同配性，表明市场中度较高的节点倾向于相互关联，这种风险关联现象的存在可能放大市场内存在的系统性风险。在动态趋势方面，2021年末以来中美整体同化率出现上升趋势，且模块度持续处于较低水平，这意味着我国股市与美国股市之间的长期联系愈加紧密。

从节点视角进一步探究中美股市的长期动态关联特征，本文绘制了长期网络的我国股市三级行业与美国股市连接次数热力图，并按连接次数降序展示前23个申万三级行业。其中，排名前10的行业包括铜、铅锌、城商行、股份制银行、铝、保险、其他小金属、大型国有银行、动力煤、焦煤行业，对应的申万一级行业为有色金属、银行、非银金融和煤炭行业。这意味着我国股市中有色金属、

金融和煤炭行业与美国股市存在长期风险关联^①。进一步聚焦于我国股市中长期风险关联具有代表性的铜行业和股份制银行行业，分析它们与标普500成分股之间的关联特征。可以看出，铜与标普500中的个股麦克莫兰铜金（FCX）、纽柯钢铁（NUE）、卡特彼勒（CAT）等存在紧密风险关联。股份制银行则与标普500中的个股金沙集团（LVS）、永利（WYNN）、卡特彼勒（CAT）和麦克莫兰铜金（FCX）等个股亦存在紧密风险交互。

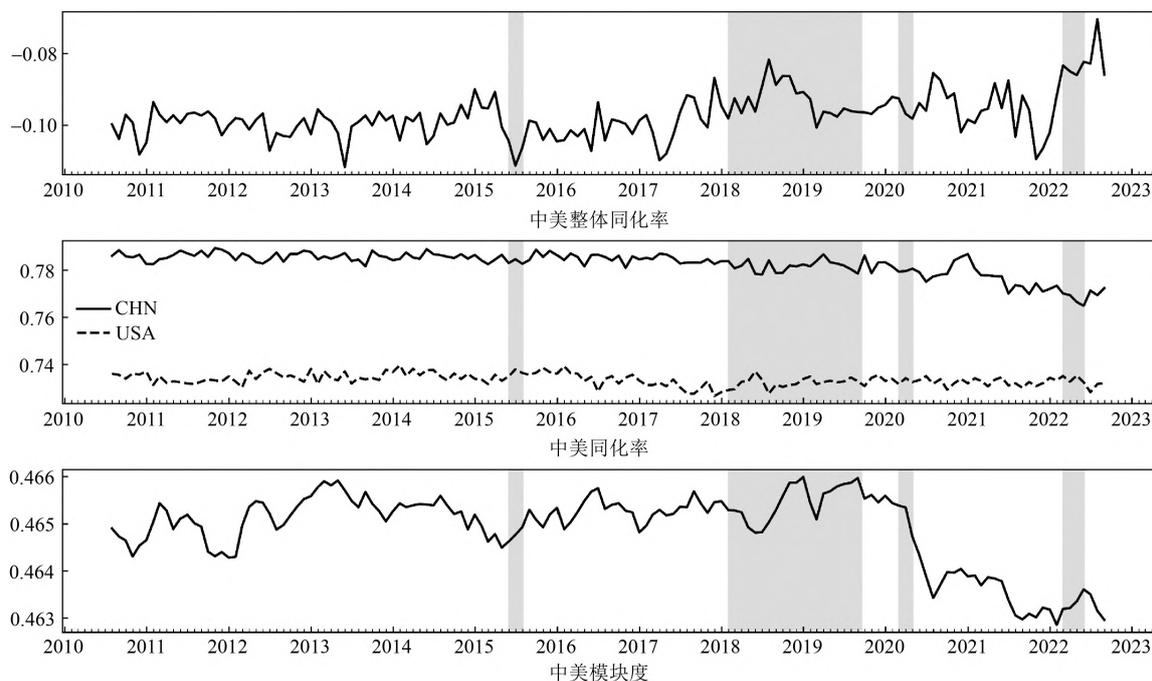


图3 长期相关系数网络的时变同化率和模块度指标

四、研究结论与启示

本文将DCC-MIDAS模型推广至超高维场景，以我国申万三级行业指数、标普500成分股作为股票市场的研究对象，同时引入中美经济政策不确定性和全球地缘政治风险指数作为宏观信息，测度中美股市高维系统的时变短期、长期相关性，进一步结合复杂网络构建与分析方法，从全局到局部、静态到动态、由点及面分析中美股市的风险交互现象。本文的主要结论有以下三个方面。第一，经济政策不确定性、地缘政治风险等宏观变量是个股波动和风险关联的重要驱动因素。相较于美国股市，我国股市波动受宏观变量的影响相对较小，表明现阶段我国金融系统对于经济政策和地缘政治冲击的敏感性相对较弱。第二，短期相关性结果表明，我国股市中的铜、铝、铅锌、板材、动力煤等三级行业是与美国股市关联的代表性节点。聚合至一级行业后，中美股市关联的重要行业则呈现为我国的金融、房地产行业，美国的能源、材料、工业行业。在欧洲债务危机、中美经贸摩擦、新冠疫情暴发等重大事件冲击下，中美股市短期关联性出现显著上升趋势。虽然我国股市短期相关性总体高于美国，但重大事件冲击下的相关性变动趋势相对平缓，体现出一定的网络韧性。第三，长期相关性结果表明，中美股市长期关联网络之间的模块度总体较为稳定。中美股市模块内部呈现“强

^①我国缺乏铁矿资源，铜精矿的外贸依存度高达80%，有色金属是国民经济发展的重要基础材料。2020年9月我国提出“碳达峰碳中和”目标后，新能源汽车行业的蓬勃发展扩大了我国对于铜矿资源的需求。

强联合”的同配性，而中美股市总体呈现异配性。具体到三级行业，我国股市中的铜、铅锌、铝等有色金属行业，城商行、股份制银行、保险等金融行业，以及动力煤、焦煤等煤炭行业与美国股市存在的长期风险关联最为显著。在动态特征方面，中美股市的长期相关性与短期趋势总体一致。

上述结论对于我国防范化解金融市场风险具有两方面启示。一方面，在把控金融风险时除了关注金融市场外，还应综合考虑经济政策、地缘政治等宏观经济信息的潜在影响，兼顾国内和国际两个方面。具体而言，工业作为国民经济的“压舱石”，在中美股市内部均处于网络中心位置，应密切关注国内机械设备、基础化工等重要工业行业的运行状况，采取积极稳定的政策保障国内大循环畅通。与此同时，也需兼具国际视角，把控中美股市间潜在的风险传递，警惕重要外资企业退出我国市场，以及美国对华高端技术企业的限制，分散因他国经济政策变化或地缘政治冲突对本国金融市场潜在产生的长期影响。同时，密切关注美联储货币政策、美国对外贸易政策的变化，缓解美国经济政策急剧变化对我国金融系统的负面影响，提高金融系统的网络韧性。另一方面，有效防范化解重大金融风险需围绕标本兼治、远近结合的基本思路，实时监测并捕捉股票市场波动所传递的全局和个体、短期和长期风险信号。在全局视角总体把握金融、房地产行业的风险波动情况，防范发达经济体股市动荡经由金融、房地产的股市行业渠道形成系统性金融风险输入，完善外来风险输入的熔断机制，防止中美股市之间系统性风险关联。在细分行业个体视角精准识别有色金属、钢铁、煤炭等行业或个股与美国股市的风险关联变动，阻断上游原材料行业的异质性冲击沿产业链向下游工业行业传导的可能性。长期视角下则需统筹防风险与稳增长。一是稳固国内有色金属与煤炭资源储备，密切关注矿产资源丰富国家的出口政策变化、推进国际合作，同时落实并推进能源消费结构改革，促进经济可持续发展与高质量增长。二是推动城商行、股份制银行、保险等金融行业的高质量发展与对外开放，促进金融市场向纵深发展，形成金融与实体经济的良性互动，从而在稳增长的基础上筑牢国家金融安全防线，化解重要风险点，守住不发生系统性金融风险的底线。

参考文献

- [1] 李政, 李丽雯, 刘淇. 中国行业间尾部风险溢出的测度及时空驱动因素研究[J]. 统计研究, 2024, 41(2): 64-76.
- [2] 杨科, 郭亚飞, 田凤平. 经济政策不确定性冲击下全球系统性金融风险的跨市场传染——基于TVP-FAVAR和TVP-VAR模型的研究[J]. 统计研究, 2023, 40(7): 70-84.
- [3] 郑挺国, 巩璐, 叶仕奇. 时变视阈下在险通货膨胀的跨国溢出研究[J]. 世界经济, 2024a, 47(12): 35-70.
- [4] 郑挺国, 张宏音, 叶仕奇. 低碳转型风险的“涟漪效应”[J]. 中国工业经济, 2024b(4): 37-56.
- [5] 周开国, 邢子煜, 杨海生. 宏观经济信息与金融市场关联性——来自混频动态条件相关系数模型的证据[J]. 金融研究, 2021, 49(11): 41-59.
- [6] Allard A F, Iania L, Smedts K. Stock-Bond Return Correlations: Moving away from “One-Frequency-Fits-All” by Extending the DCC-MIDAS Approach[J]. International Review of Financial Analysis, 2020, 71: 101557.
- [7] Asgharian H, Christiansen C, Hou A J. Macro-Finance Determinants of the Long-Run Stock-Bond Correlation: The DCC-MIDAS Specification[J]. Journal of Financial Econometrics, 2016, 14(3): 617-642.
- [8] Bardoscia M, Barucca P, Battiston S. The Physics of Financial Networks[J]. Nature Reviews Physics, 2021: 1-18.
- [9] Barigozzi M, Hallin M. A Network Analysis of the Volatility of High Dimensional Financial Series[J]. Journal of the Royal Statistical Society Series C: Applied Statistics, 2017, 66(3): 581-605.
- [10] Brownlees C, Guðmundsson G S, Lugosi G. Community Detection in Partial Correlation Network Models[J]. Journal of Business & Economic Statistics, 2022, 40(1): 216-226.
- [11] Colacito R, Engle R F, Ghysels E. A Component Model for Dynamic Correlations[J]. Journal of Econometrics, 2011, 164(1): 45-59.
- [12] Conrad C, Loch K. Anticipating Long-Term Stock Market Volatility[J]. Journal of Applied Econometrics, 2015, 30(7): 1090-1114.
- [13] Diebold F X, Yilmaz K. On the Network Topology of Variance Decompositions: Measuring the Connectedness of Financial Firms[J]. Journal of Econometrics, 2014, 182(1): 119-134.

- [14] Dietrich A M, Kuester K, Müller G J. News and Uncertainty about COVID-19: Survey Evidence and Short-Run Economic Impact[J]. *Journal of Monetary Economics*, 2022, 129: S35–S51.
- [15] Engle R. Dynamic Conditional Correlation: A Simple Class of Multivariate Generalized Autoregressive Conditional Heteroskedasticity Models[J]. *Journal of Business & Economic Statistics*, 2002, 20(3): 339–350.
- [16] Engle R F, Ghysels E, Sohn B. Stock Market Volatility and Macroeconomic Fundamentals[J]. *Review of Economics and Statistics*, 2013, 95(3): 776–797.
- [17] Engle R F, Ledoit O, Wolf M. Large Dynamic Covariance Matrices[J]. *Journal of Business & Economic Statistics*, 2019, 37(2): 363–375.
- [18] Fang L, Yu H, Li L. The Effect of Economic Policy Uncertainty on the Long-Term Correlation Between US Stock and Bond Markets[J]. *Economic Modelling*, 2017, 66: 139–145.
- [19] Gabaix X, Gopikrishnan P, Plerou V, et al. A Theory of Power-Law Distributions in Financial Market Fluctuations[J]. *Nature*, 2003, 423(6937): 267–270.
- [20] Hu Z, Kutan A M, Sun P W. Is US Economic Policy Uncertainty Priced in China's A-Shares Market? Evidence from Market, Industry, and Individual Stocks[J]. *International Review of Financial Analysis*, 2018, 57: 207–220.
- [21] Ledoit O, Wolf M. Nonlinear Shrinkage Estimation of Large-Dimensional Covariance Matrices[J]. *Annals of Statistics*, 2012, 40(2): 1024–1060.
- [22] Ledoit O, Wolf M. Analytical Nonlinear Shrinkage of Large-Dimensional Covariance Matrices[J]. *Annals of Statistics*, 2020, 48(5): 3043–3065.
- [23] Li X, Ye C, Bhuiyan M A, et al. Volatility Forecasting with an Extended GARCH-MIDAS Approach[J]. *Journal of Forecasting*, 2024, 43(1): 24–39.
- [24] Massara G P, Di Matteo T, Aste T. Network Filtering for Big Data: Triangulated Maximally Filtered Graph[J]. *Journal of Complex Networks*, 2017, 5(2): 161–178.
- [25] Pakel C, Shephard N, Sheppard K. Fitting Vast Dimensional Time-Varying Covariance Models[J]. *Journal of Business & Economic Statistics*, 2021, 39(3): 652–668.
- [26] Perego E R, Vermeulen W N. Macro-Economic Determinants of European Stock and Government Bond Correlations: A Tale of Two Regions[J]. *Journal of Empirical Finance*, 2016, 37: 214–232.
- [27] Schwert G W. Why Does Stock Market Volatility Change over Time?[J]. *Journal of Finance*, 1989, 44(5): 1115–1153.
- [28] Song W M, Di Matteo T, Aste T. Hierarchical Information Clustering by Means of Topologically Embedded Graphs[J]. *PLoS ONE*, 2012, 7(3): e31929.
- [29] Yu X, Huang Y. The Impact of Economic Policy Uncertainty on Stock Volatility: Evidence from GARCH-MIDAS Approach[J]. *Physica A: Statistical Mechanics and Its Applications*, 2021, 570: 125794.
- [30] Zaremba A, Cakici N, Demir E, et al. When Bad News Is Good News: Geopolitical Risk and the Cross-Section of Emerging Market Stock Returns[J]. *Journal of Financial Stability*, 2022, 58: 100964.

作者简介

郑挺国，厦门大学经济学院和宏观经济研究中心教授、博士生导师。研究方向为大数据宏观经济监测预测、复杂经济系统建模分析、宏观经济风险管理。

叶仕奇（通讯作者），中国科学院数学与系统科学研究院助理研究员。研究方向为高维时变复杂系统建模与分析、大数据经济系统监测预测、得分驱动方法与应用、大数据经济政策评估。电子邮箱：shiqi.ye.c@gmail.com。

范小龙，招商银行跨境金融部。研究方向为跨境金融、风险管理、金融计量。

张宏音，厦门大学王亚南经济研究院博士研究生。研究方向为宏观计量、时间序列分析、气候风险评估。

（责任编辑：耿雪洋）