

doi:10.19920/j.cnki.jmsc.2023.04.001

# 基于非参数因果网络的风险溢出分析及多因子预测<sup>①</sup>

王宗润, 周玲, 米允龙  
(中南大学商学院, 长沙 410083)

**摘要:** 风险溢出是系统性金融风险产生和演化的核心动因, 因此, 探究风险的溢出路径与强度至关重要. 为了弥补传统方法在维度与参数上的局限, 本文将非参数条件互信息检验与因果网络结构学习算法相结合, 提出了一种新的非参数高维因果网络构建方法来分析金融系统波动溢出的动态联动性和风险传递机制. 本文在非线性合成数据集中验证了该方法的有效性和稳健性并根据因果拓扑关系构造最优预测子集对序列进行多因子预测. 并将该模型应用于构建 2013 年 1 月至 2019 年 12 月期间全球 81 家能源公司月度股票收益的波动溢出网络, 测量基本面与投资者两种维度的风险溢出强度动态变化并进行预测分析. 此外, 结合企业财务数据和宏观经济变量, 考虑企业之间的业务异质性, 探索风险溢出的决定因素. 研究表明, 1) 能源产业链的上游以及高油价风险敞口的能源企业表现出较大的风险外溢效应和风险承受程度; 2) 除公司规模以外, 企业资产收益率, 边际收益等因素也影响溢出效应的强弱; 3) 能源公司的风险溢出在业务上存在很大差异, 溢出驱动因素也有所不同, 这对于在投资组合决策和监管政策设计等具有重要的参考价值; 4) 虽然因果预选信息选择策略结合非参数模型的短期预测效果要优于结合参数模型, 但是随着预测步长的增加, 参数模型的优势却更明显.

**关键词:** 因果网络; 非参数因果网络结构学习算法; 风险溢出; 多因子预测

**中图分类号:** F830.9 **文献标识码:** A **文章编号:** 1007-9807(2023)04-0001-19

## 0 引言

风险的传染效应对金融体系具有巨大的破坏性, 并常会引发经济衰退, 因此对风险传染的研究有着重要的理论价值和现实意义<sup>[1, 2]</sup>. 随着能源市场一体化和金融化的发展, 能源市场的风险传染已成为风险传染研究的重要组成部分. 能源公司通过能源价格、股票市场和金融合同相互关联, 构成了能源部门内风险溢出和系统性风险出现的内在动因<sup>[3-5]</sup>. 具体来说, 首先, 能源企业之间存在着很强的相关性, 因为能源价格与国际原油价格密切相关<sup>[6-10]</sup>; 其次, 能源企业可以通过股票市场对其他企业施加风险溢出. 此外, 衍生品的广

泛使用还可能为能源行业内的金融交流提供一个强大的渠道<sup>[11]</sup>. 然而, 目前缺乏实证研究来探讨能源企业风险传染路径、强度及其决定因素.

近年来从相关性视角来考察风险传染已成为学术领域的一个普遍共识<sup>[12-14]</sup>, 其中使用的主要计量模型包括: Copula 类模型<sup>[15-17]</sup>、尾部相关类模型<sup>[18]</sup>与互信息<sup>[19]</sup>等. 例如, 沈传河和王向荣<sup>[20]</sup>通过构建一种基于支持向量机和 Copula 函数的集成系统, 得到货币市场与资本市场之间的相依结构及其动态特性. Zhu 等<sup>[21]</sup>使用尾部依赖系数评估了全球 124 家能源企业风险溢出的规模和持续性. Fiedor<sup>[22]</sup>使用互信息衡量纽约证券交易所的 100 支股票数据, 分析其非线性相关关系. 然而

① 收稿日期: 2021-04-22; 修订日期: 2022-06-20.

基金项目: 国家自然科学基金资助重大项目(72091515); 国家自然科学基金资助基础科学中心项目(72088101).

作者简介: 王宗润(1973—), 男, 湖南沅陵人, 博士, 教授, 博士生导师. Email: zrwang0209@sina.com

受方法的二元性和无向性的制约,这些建立于可观测数据的网络关联结构并不能很好地描述出机构、部门或行业之间内在关系的方向性和复杂性。

为了进一步探索金融传染的方向性,从经验数据中推断因果关系的计量模型越来越成为研究热点并取得了实质性进展。例如,韩佳彤等<sup>[23]</sup>通过格兰杰检验对主板市场与创业板市场的收益率以及定单流之间的关系进行研究,结果表明主板市场对创业板市场有着较强的引领作用。总体来看,时间序列因果推理研究中主要使用的金融计量模型有:向量自回归(VAR)及其扩展模型,GARCH及其扩展模型与转移熵等。Balli等<sup>[24]</sup>运用基于VAR模型的溢出分析和网络图研究了22个商品不确定性指标之间的滚动相关性。宫晓莉和熊熊<sup>[25]</sup>利用基于时变向量自回归模型(TVP-VAR)的方差分解溢出指数分析了多个市场之间的时变波动溢出和风险传递机制。此外,许多研究使用了GARCH模型<sup>[26-28]</sup>,特别是一些研究考虑在外生冲击下模型参数的变化,如李合龙等<sup>[29]</sup>采用BEKK-GARCH模型分析金融危机前一中一后我国股票市场行业间的波动溢出效应。Ewing和Malik<sup>[30]</sup>使用迭代累积平方和(ICSS)算法和BEKK-GARCH模型分析了黄金市场和原油期货市场之间的波动传递。从信息论的角度来看,转移熵逐渐成为推断信息流方向和强度的常用度量<sup>[31-33]</sup>。Ji等<sup>[34]</sup>使用基于时变转移熵的方法来识别农产品和能源商品回报的风险溢出的方向。需要指出的是VAR类模型重点在于预测而不是对变量之间因果关系的评估,且具有线性假设和维数的限制。GARCH类模型需要估计大量的参数,单个系数的精确解释也很困难。向量自回归模型、Granger因果检验和转移熵的原始形式都是二元且收敛,这类方法不适合中高维时间序列的数据集。而格兰杰因果检验通常局限于线性关系,转移熵虽然能捕捉到非线性的相互作用,但需要非常大的数据量来估计概率密度函数。

金融市场本质上是一类典型的复杂系统,防范和化解重大金融风险不仅需要全局性的系统思考,更需要从技术和方法的角度借助金融复杂性分析工具。实际上,因果网络是一种较为理想的

将风险传递方向与路径可视化的金融复杂性分析工具。Verma和Pearl<sup>[35]</sup>基于Bayes网络引入了外部干预的概念,首次提出因果网络模型,创立了基于结构因果模型的因果研究框架。因果网络基于条件独立性框架,具有马尔可夫性质,可以用有向无环图(DAG)来表示。其应用领域广泛,包括人工智能、决策支持系统、遗传学、地质学、医学和金融等。然而连续随机变量的图形建模主要局限于多元正态分布。其原因为DAG的可用结构估计算法(如PC(Peter and Clark)算法<sup>[36]</sup>、IC(Inductive Causation)算法<sup>[37]</sup>和Stable PC算法<sup>[38]</sup>)通常局限于离散或高斯变量。且不能直接用于时间序列。

本文提出了一种适用于非高斯连续随机变量的因果网络构造方法并估计其潜在马尔可夫结构。其中,通过设定最大滞后时间缩小初始条件集合的大小来加快运算速度,并可以分为两个步骤来学习因果结构。第一步,执行PC算法得到各个变量的初始条件集合,此步受到序列自相关的影响使得条件集中具有较高的假阳性率。第二步,通过对条件集中变量的进一步筛选,移除集中由间接驱动和共同驱动导致的虚假因果关系,最终得到完整的因果网络结构。该因果网络结构学习算法可以嵌入不同类型的条件独立性检验统计量。与传统的线性条件相关检验不同,该算法通过将Vejmelka和Palus<sup>[39]</sup>提出的基于信息论的非参数耦合方向性检验统计量嵌入其中,以量化因果信息的非线性传递,打破了因果网络的高斯分布局限性。此外,为了证明所提方法的有效性和稳定性,在非线性合成数据集中进行了大量的仿真实验,得到的结果支持本研究的结论。

时间序列的多因子预测是一个具有挑战性的问题,尤其是使用无模型方法。大多数无模型方法,如最近邻算法或神经网络<sup>[40]</sup>,应用主要局限于单变量情况。若考虑了更多变量和更大时间滞后,则预测器子集的可能组合会呈指数增长,使得这些方法面临维数灾难和过度拟合的问题。然而,复杂系统的交织特性要求采用多变量方法,考虑更多可用信息。高效利用可用信息的信息选择策略对预测器的正确组合很重要。在非参数因果网络结构学习算法的基础上采用因果预选信息策

略,根据条件互信息的大小选择最优的预测子集. 具体来说,将预测子集的搜索局限于具有因果驱动关系的节点集合中,随后再结合无模型的预测技术,有效的解决了传统无模型预测技术的局限性.

基于本研究提出的风险溢出的因果网络分析框架,揭示了2013年1月至2019年12月期间影响全球81家不同业务的能源公司之间时变风险溢出的驱动因素. 具体而言,基于能源企业股票收益率的非参数因果网络,得到基本面渠道和投资者渠道的风险溢出指标,揭示具有系统重要性的能源企业特征和演变. 此外,还对不同业务的能源企业风险溢出驱动因素进行了面板回归分析. 实证研究结果为能源企业的风险溢出驱动因素管理提供了理论依据.

本研究的主要贡献如下:1)提出了一种非参数因果网络结构学习算法,并对其准确性和稳健性进行了非线性合成数据验证,这为高维非线性数据集的因果网络构建提出了一个数据驱动的非参数方案. 2)提出了一个适用于多因子预测的信息选择策略,给出了长期与短期的多因子预测最优范式. 3)构建了能源股票市场的风险溢出网络,度量并分析了基本面和投资者渠道的风险溢出效应;探索了企业溢出效应的驱动因素,并通过对风险因素和机制的微观分析,为能源金融市场风险管理的政策设计提供了坚实的理论基础.

## 1 理论模型

首先给出因果网络的构建方法,具体可分为:识别因果关系和学习因果结构. 再而,根据因果网络的拓扑结构得到相应的基本面渠道和投资者渠道的风险溢出指标. 最后,提出基于因果预选的信息策略来改进无模型预测方法进行多因子预测.

### 1.1 因果网络的构建

#### 1.1.1 识别因果关系: 非参数条件互信息检验

揭示因果方向性是理解复杂系统中驱动—响应关系的一个重要步骤. 由于基于信息论的泛函统计量具有非参数性质使得其在检测复杂系统的关系时具有广泛的适用性. 考虑离散随机变量  $X$ ,

$Y$  以及其对应值域  $\chi, Y$  概率分布函数  $P(X)$ ,  $P(Y)$ , 联合概率分布函数  $P(X, Y)$ .  $X, Y$  的互信息可表示为  $I(X; Y) = H(X) + H(Y) - H(X, Y)$ , 其中熵  $H(X), H(Y)$  定义为

$$H(X) = - \sum_{X \in \chi} P(X) \ln P(X)$$

$$H(Y) = - \sum_{Y \in Y} P(Y) \ln P(Y)$$

联合熵  $H(X, Y) = - \sum_{X \in \chi} \sum_{Y \in Y} P(X, Y) \ln P(X, Y)$ . 那么有  $X, Y$  在给定随机变量  $Z$  时的条件互信息及其熵可表示为

$$I(X; Y | Z) = I(X; Y; Z) - I(X; Z) - I(Y; Z)$$

$$I(X; Y | Z) = H(X, Y) + H(X, Z) - H(Z) - H(X, Y, Z) \quad (1)$$

Kozachenko 和 Leonenko<sup>[41]</sup> 根据样本空间的

最近距离导出了熵的估计值  $\hat{H}(X) = \sum_{j=1}^N (N \rho_j) + \ln 2 + C_E$ , 并证明了估计量的一致性. 其中  $\rho_j$  表示第  $j$  个样本到最近邻点的距离,  $N$  为样本的数量,  $C_E$  为 Euler-Mascheroni 常数,  $C_E \approx 0.577 2$ . 基于 Kozachenko 的研究, Kreuz 等<sup>[42]</sup> 提出了一种基于最近邻法计算互信息的方法, 详情如式(2)所示, 并证明了最近邻法比最近距离法具有更好的统计性质. 此外, Goria 等<sup>[43]</sup> 证明了基于最近邻法的熵估计量是一致的

$$I(X; Y) = \phi(K) + \phi(N) - \langle \phi(n_x + 1) + \phi(n_y + 1) \rangle \quad (2)$$

其中  $K$  是经过距离计算后的邻点的秩,  $\phi(\cdot)$  为 Gamma 函数的对数导数即  $\phi(x) = d(\ln \Gamma(x))/dx$ , 对于联合空间的每个点, 找到其第  $K$  个最近邻居的距离  $\varepsilon_K$ . 搜索子空间  $X$  和  $Y$ , 求出当前点周围半径为  $\varepsilon_K$  的超球体中的点数记为  $n_x, n_y$ .  $\langle \cdot \rangle$  表示所有可用数据点的平均值, 在距离的计算中可以选择任何度量. 在本研究中, 使用基于 L1 - 范数的曼哈顿距离来度量. 同样的基于最近邻的条件互信息可表示为

$$I(X; Y | Z) = \phi(K) - \langle \phi(n_{XZ} + 1) + \phi(n_{YZ} + 1) - \phi(n_Z + 1) \rangle \quad (3)$$

其中  $n_{XY}, n_{YZ}, n_Z$  为  $X, Y, Z$  联合空间中任意参考点的近邻点个数.  $K$  为  $X \otimes Y \otimes Z$  联合空间的

任意参考点的近邻点个数. 若  $I(X, Y | Z) > I_{threshold}$ , 则在给定  $Z$  的条件下  $X, Y$  存在相关性<sup>②</sup>.

1.1.2 学习因果结构: 因果结构学习算法

考虑  $m$  维时间序列  $\{X_t^1, X_t^2, \dots, X_t^m\}, t = 1, 2, \dots, T$ , 构建多维时间序列因果网络  $g(V \times T, E)$ . 在每个  $t \in [1, T]$  有点集  $V$ , 边集  $E$  由  $x_{t-\tau}^i$  与  $x_t^j$  的特定滞后阶数  $\tau$  的有向边  $x_{t-\tau}^i \rightarrow x_t^j$  构成, 其中  $x_{t-\tau}^i$  称为  $x_t^j$  的因节点. 边权重为条件互信息  $e_{ij}^\tau = I(x_t^j, x_{t-\tau}^i | P(x_t^j))$ , 其中  $P(x_t^j) = \{x_{t-\tau}^k : k \in [1, m], \tau > 0, x_{t-\tau}^k \rightarrow x_t^j\}$  表示与  $x_t^j$  存在条件相关关系的点集. 如何选择条件互信息的条件相关点集是因果网络结构学习算法的关键. 本文提出的因果网络结构学习算法对传统的 PC 算法存在两点改进: 首先, 设置初始条件集合的大小为有限的滞后时间与时间序列维度的乘积, 大大减少了算法运行时间. 其次, 对运行一次 PC 算法后得到的联合条件集再次进行集合中节点之间的条件相关检验, 淘汰间接相关和共同驱动虚假连接. 将因果结构学习算法应用于多维时间序列数据集的具体步骤如下:

**步骤 1** 从一个完整的全连接网络开始, 初始条件集为有限的滞后时间与时间序列维度的乘积

$$P(X_t^i) = \{x_{t-\tau}^i : i = 1, 2, 3, \dots, N; \tau = 1, 2, 3, \dots, \tau_{max}\}$$

其中  $N$  为时间序列维度,  $\tau_{max}$  为最大滞后时间.

**步骤 2** 设置一定的显著性水平  $\alpha$ , 从条件集中迭代移除检验的  $P$  值小于阈值  $\alpha$  的点. 即若统计量  $I(x_t^i, x_{t-\tau}^s | P(X_t^i) \setminus \{x_{t-\tau}^s\})$  的  $P$  值小于  $\alpha$ , 则从条件集  $P(X_t^i)$  中移除  $\{x_{t-\tau}^s\}$ ; 反之则保留在条件集中. 将  $I(x_t^i, x_{t-\tau}^s | P(X_t^i) \setminus \{x_{t-\tau}^s\})$  记为  $I(x_{t-\tau}^s \rightarrow x_t^i), s = 1, 2, \dots, N, x_{t-\tau}^s$  为  $x_t^i$  的因节点.  $x_{t-\tau}^s$  按统计量的大小排序, 记为  $x_t^i$  的条件集  $\tilde{P}(x_t^i)$  (见图 1). 此时条件点集中保留了存在因果关系的真连接, 但也保留了一些虚假因果关系的假阳性连接, 这种虚假的因果关系主要是由于共同驱动和间接驱动所引起的 (共同驱动: 即由于  $A \rightarrow$

$B, A \rightarrow C$  使得存在  $B \rightarrow C$  的虚假连接; 间接驱动: 即由于  $A \rightarrow B, B \rightarrow C$  使得存在  $A \rightarrow C$  的虚假连接. 见图 2).

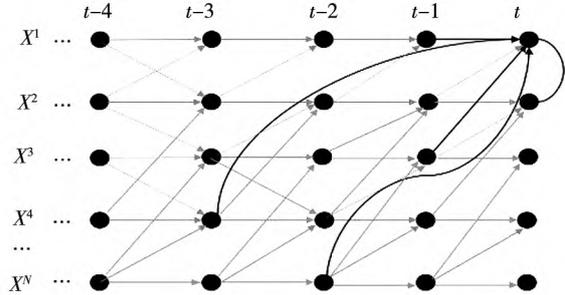


图 1 步骤 2 中从初始全连接网络中去除  $P$  值小于  $\alpha$  的连接示意图  
Fig. 1 Removing connections with  $P$ -values less than  $\alpha$  from the initial fully connected network in step 2

**步骤 3** 设置因节点条件集合的元素个数上

限  $\max, \tilde{P}_{max}(x_{t-\tau}^j)$  为节点  $x_{t-\tau}^j$  的经步骤 2 得到的条件集合的前  $\max$  个元素. 将因节点的条件集合  $\tilde{P}_{max}(x_{t-\tau}^j)$  与该节点去掉被测因节点的条件集合  $\tilde{P}(x_t^i) \setminus \{x_{t-\tau}^j\}$  合并为一个条件集合, 记为  $C(x_{t-\tau}^j \rightarrow x_t^i) = \{\tilde{P}(x_t^i) \setminus \{x_{t-\tau}^j\}\} \cup \tilde{P}_{max}(x_{t-\tau}^j)$ , 即计算每一对点  $x_{t-\tau}^j \rightarrow x_t^i$  的条件互信息  $I(x_{t-\tau}^j, x_t^i | C(x_{t-\tau}^j \rightarrow x_t^i))$  来排除间接和共同驱动. 若  $P$  值大于显著性水平  $\alpha$ , 连接  $x_{t-\tau}^j \rightarrow x_t^i$  保留在网络中, 否则删除连接.

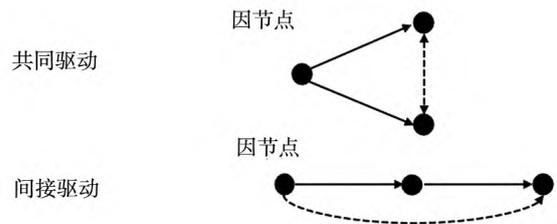


图 2 共同驱动和间接驱动  
Fig. 2 Common and indirect drive

注: 虚线箭头代表由于共同或间接驱动产生的虚假连接.

1.2 基于因果网络的风险溢出指标

风险的溢出可以通过基本面渠道或与投资者相关的渠道传播. 一方面, 当溢出是基于基本面时, 意味着它与实际因素有关, 如国际贸易和外国直接投资, 表现为危机前后网络整体拓扑结构的

② 设置阈值  $I_{threshold}$  为当  $P$  值  $\alpha = 0.05$  时的非参数条件互信息检验统计量值.

变化. 另一方面, 如果风险的传递是基于投资者行为, 那么由于投资者财富或投资组合的再平衡, 通过将资金从风险较高的资产转移到风险较低的资产, 从而调整投资组合风险. 在危机期间, 投资者的转移行为更为常见, 表现为危机前后网络单个节点拓扑结构的变化.

从整个金融系统来看, 危机前后网络整体边缘强度的变化反应了风险溢出的基本面渠道. 在此, 定义系统风险溢出强度为溢出网络所有边的权重之和

$$Sys = \sum_{i,j=1, i \neq j}^N I_{ij}^{\tau} \quad (4)$$

其中  $I_{ij}^{\tau}$  为  $i \rightarrow j$  的滞后时间为  $\tau (0 \leq \tau \leq \tau_{\max})$  的非参数条件互信息. 下列指标代表了风险溢出的投资者渠道, 定义从该资产外溢到其他资产的总溢出强度为对外溢出效应 ( $To_i$ )

$$To_i = \sum_{j=1, i \neq j}^N I_{ij}^{\tau} \quad (5)$$

其它资产外溢到该资产的总风险定义为风险承受程度 ( $From$ )

$$From_i = \sum_{j=1, i \neq j}^N I_{ji}^{\tau} \quad (6)$$

基于式(5)与式(6), 进一步定义净溢出效应为对外溢出效应 ( $To_i$ ) 与受其他市场溢出的风险承受程度 ( $From$ ) 的差值, 即  $Net_i = To_i - From_i$

### 1.3 基于因果网络的多因子预测: 因果预选信息策略

现阶段最常用的非参数时间序列预测方法是最近邻预测, 即在时序中搜索与当前状态相似的状态, 并且简单的使用过去相似状态的平均值或者局部线性模型来进行预测. 然而, 最近邻预测在高维情况下经常会有维数灾难和过拟合问题. 为了规避维数灾难和过拟合, 本研究在进行目标变量的预测之前添加因果预选步骤来选择最优预测变量集合. 具体而言, 在多维时间序列中搜索与当前状态具有因果驱动关系的状态构成预测器的各种组合来进行预测, 这样的信息选择策略极大的缩小了搜索范围和预测器的可能组合数. 考虑  $N$

维随机过程  $X$  的子过程  $Y$  随时间变化的函数为

$$Y_{t+l} = f(H_{Y_{t+l}}, \xi_{t+l}^Y) \quad (7)$$

$H_{Y_{t+l}}$  表示  $Y_{t+l}$  的决定性驱动变量集合,  $H_{Y_{t+l}} \subseteq \{X_t, X_{t-1}, \dots\}$ ,  $\xi_{t+l}^Y$  为噪声项. 基于信息论的角度, 决定性驱动变量集合  $H_{Y_{t+l}}$  对  $Y_{t+l}$  的预测十分重要, 但集合  $H_{Y_{t+l}}$  的元素含有大量冗余的信息会造成过拟合. 所以选择一个合适的驱动变量子集  $H_{Y_{t+l}}^h$  是一项非常有意义的工作. 在上文中, 已经通过因果网络结构学习算法得到了每一个点的条件因节点集合  $\tilde{P}(x_t^i)$ , 将其作为预测工作所需要的决定性驱动变量子集且满足  $\tilde{P}(x_t^i) \subseteq \{X_t, X_{t-1}, \dots\}$ . 下面选择  $h$  个最佳预测因节点  $H_{Y_{t+l}}^h \subseteq \tilde{P}(x_t^i)$ , 集合  $H_{Y_{t+l}}^h$  是具有最大互信息的最小集合, 故采用的标准是将因节点集合中的变量按照与预测变量  $Y_{t+l}$  的互信息进行排序

$$I(X^{(1)}; Y_{t+l}) > I(X^{(2)}; Y_{t+l}) >$$

$$I(X^{(3)}; Y_{t+l}) > \dots > I(X^{(n)}; Y_{t+l})$$

选择一个适当的阈值<sup>③</sup>  $\lambda \in [0, 1]$ , 第  $h$  个因节点应该满足以下条件

$$I(X^{(h)}; Y_{t+l} | (X^{(1)}, X^{(2)}, \dots, X^{(h-1)})) >$$

$$\lambda I((X^{(1)}, X^{(2)}, \dots, X^{(h-1)}); Y_{t+l})$$

下面分别结合非参数模型和参数模型进行预测. 对所有预测  $H_{Y_{t+l}}^h$  中的点  $s$ , 定义距离  $d_{t,s} = \|H_{Y_{t+l}}^h - H_s^h\|$ , 然后将距离进行排序  $d_{t,s_1} < d_{t,s_2} < \dots < d_{t,s_h}$ , 得到因节点序列  $s_1, s_2, \dots, s_h$ . 那么, 对  $Y_{t+l}$  的最近邻预测(CI + KNN)可以根据距离大小取加权平均,  $\frac{1}{K_j}$  为相应的权重<sup>④</sup>,  $Y_{s_j}$  为因节点  $s_j$  的值

$$\hat{Y}_{t+l} = \frac{1}{K_j} \sum_{j=1}^h Y_{s_j}$$

$$\hat{\sigma}(\hat{Y}_{t+l}) = \sqrt{\frac{1}{K_j} \sum_{j=1}^h (Y_{s_j} - \hat{Y}_{t+l})^2} \quad (8)$$

此外还可以选择结合线性回归方法(CI + Linear)来进行预测:  $\hat{Y}_{t+l} = H_{Y_{t+l}}^h \hat{\beta} + \varepsilon_t$ ,  $\hat{\sigma}(\hat{Y}_{t+l}) =$

③ 在本文的实验中  $\lambda$  选择 20%.

④ 本文 3.4 节的实验中最近邻预测采用等权重方法, 即  $K_j$  等于因节点的个数.

$$\sqrt{\widehat{\sigma}_e^2 + \sum_{j=1}^h \widehat{\sigma}(\widehat{\beta}_j)^2 Y_{sj}^2} \tag{9}$$

## 2 模型效果与稳健性检验

为了评估本研究提出的因果网络在非线性高维数据集中的有效性和结果的稳健性,比较了本研究所提出的模型(Conditional Non-parameters Mutual Information, CI)与基于 PC 算法得到的因果网络的真阳性率和假阳性率. 使用一个多维非线性数据生成模型来模拟真实数据的属性,合成数据真实的潜在关系是已知的,分别用经典的 PC 算法和非参数因果网络算法(CI)来复原数据之间的关系. 模拟数据集具有非线性、高维性、自相关性和因果依赖性的特点,其产生方法如下:对于  $i, j \in \{1, 2, \dots, N\}$ , 根据函数

$$x_t^i = a_j x_{t-1}^j + cf(x_{t-\tau_i}^i) + \eta_t^i$$

随机产生  $i, j$  序列间的连接(为了简化验证,默认产生连接数为  $2N$ ,  $N$  为数据维度,故每个序列的因果依赖关系唯一).  $a_j$  从集合  $\{0, 0.2, 0.4, 0.6, 0.8, 0.9\}$  中均匀抽取,噪声服从标准正态分布  $\eta_t^i \sim N(0, 1)$ , 时间延迟期数服从两点分布  $\tau_i \sim B(0, 1)$ .

使用两种函数得到非线性数据  $f(x) = f_1(x) = (1 - 4e^{-x^2/2})x$  或者  $f(x) = f_2(x) = (1 - 4x^3 \times e^{-x^2/2})$ , 产生每种连接的概率各为 50%.  $c$  为因果依赖强度系数,设为常数 0.25. 选取 0.01 为非线性条件独立性检验的显著性水平,模拟当时间序列维度为  $\{10, 20, 40, 60, 80, 100\}$ , 序列长度为 500 或 1 000 的非线性时间序列数据集. 对每个维度做 20 组随机实验,得到 CI 算法和 PC 算法产生网络连接的真正阳性率和假阳性率的平均值. 结果如表 1 和图 3 所示.

表 1 模型效果与稳健性检验结果

Table 1 The results of model effect and robustness test

序列维度	非参数因果网络算法(CI)		PC 算法(PC)	
	真阳性率	假阳性率	真阳性率	假阳性率
$N = 10, T = 500$	0.984	0.047	0.597	0.05
$N = 20, T = 500$	0.895	0.052	0.484	0.03
$N = 40, T = 500$	0.843	0.054	0.587	0.03
$N = 60, T = 500$	0.826	0.055	0.432	0.01
$N = 80, T = 500$	0.812	0.056	0.536	0
$N = 100, T = 500$	0.804	0.044	0.538	0
$N = 10, T = 1\ 000$	0.994	0.049	0.662	0.04
$N = 20, T = 1\ 000$	0.955	0.050	0.632	0.03
$N = 40, T = 1\ 000$	0.907	0.055	0.658	0.02
$N = 60, T = 1\ 000$	0.874	0.053	0.603	0
$N = 80, T = 1\ 000$	0.862	0.054	0.582	0
$N = 100, T = 1\ 000$	0.854	0.055	0.557	0

注: 真阳性率和假阳性率为每组 20 次实验的平均值.

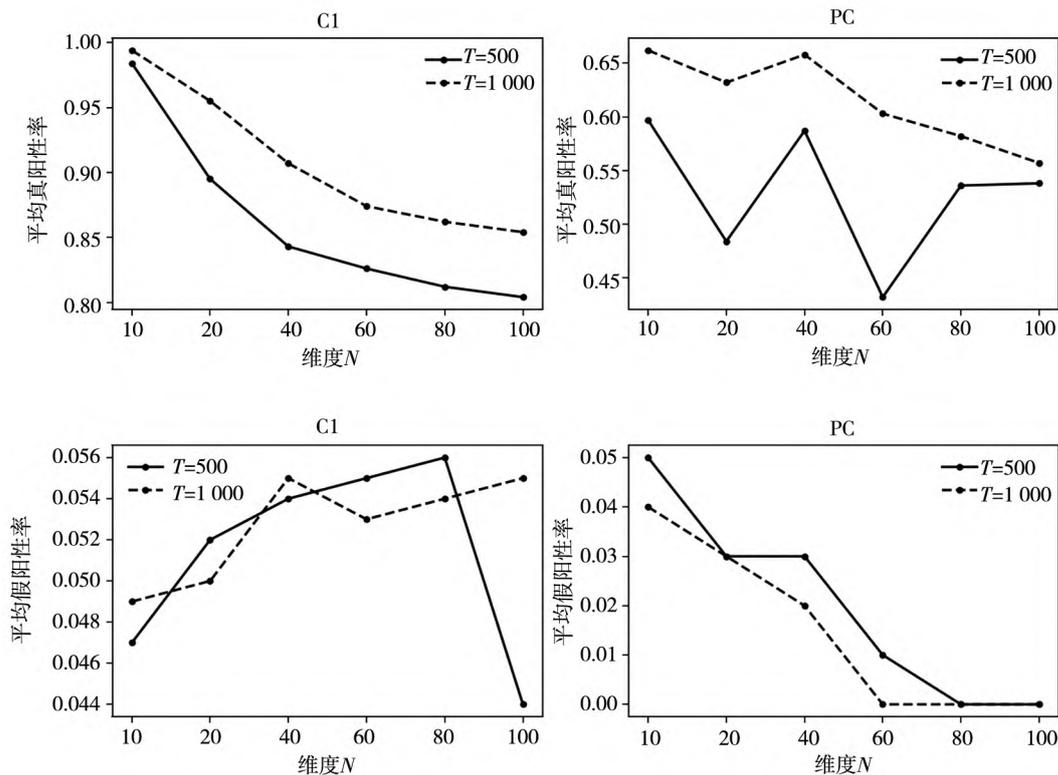


图3 CI(左)与PC(右)算法的仿真实验结果

Fig. 3 The result of CI (left) and PC (right) algorithm simulation experiment

非参数因果网络算法在所有维度上都表现出较高的真阳性率,在区间(0.80,0.99)中.并且真阳性率的实验结果在时间序列维度和区间长度的变化下表现稳定,进一步证明了模型的实验结果具有稳健性.此外,CI算法的平均假阳性率控制在0.05左右,并随着序列维度的增加而增加,但结果稳定未出现较大幅度的震荡.样本时间长度的增加对模型的表现有积极的作用.PC算法的平均真阳性率在(0.44,0.66)之间,平均真阳性率也随着序列维度的升高有一定幅度的降低.显然,PC算法在真阳性率上表现远差于非参数因果网络算法,但其对假阳性率控制能力更优.综上,本研究提出的因果网络构建的方法适用于维数较高的非线性时间序列数据集,真阳性的比率较高,并且将假阳性率控制在合理的范围之内.

### 3 实证分析

#### 3.1 数据来源

本研究主要收集了2013年1月4日—2019年12月31日期间美国81家上市公司的每日对

数股票收益率和季度财务数据.所选公司属于北美行业分类系统中的采矿、采石和油气开采部门,所有数据来源于OSIRIS全球上市公司财务分析库.采用以下两个标准来选择能源公司并构建数据集.第一个标准要求被选中的公司总资产排在全美前250,并在纽约证券交易所或纳斯达克证券交易所上市,这保证了被选中的公司将是市场上最大的参与者之一,其股票具有高度流动性.第二个标准涉及上市年份,所选公司需要在2013年之前上市以确保有足够的数据来估计本研究的结果并与季度财务数据相匹配.此外,省略了法定假日期间的收益率,当一家公司的数据连续30d或超过15%的时间缺失时,也省略了相应的样本.采用线性插值法代替剩余的缺失数据.因此,最终数据集由81家采矿、采石和油气开采行业公司2013年1月4日—2019年12月31日的1762份每日收益组成.并进一步采用公司特定的季度频率变量对溢出效应进行了实证分析.为了深入了解企业业务类型与风险溢出效应的关系,根据北美行业分类系统的三级分类进一步将这些企业分为不同类型.选定的公司可分为5个业务,即包括煤炭开采、非金属矿产

开采和采石、采矿支持活动、金属矿开采与油气开采。该分类涵盖了所选样本公司的所有主要业务类型,这使得本研究能够从业务角度对公司层面的风险溢出进行全面调查。

图4显示了五类不同业务的能源公司股票平均对数收益率变化,标注了四个典型事件,2014年中期到2015年由供需驱动的油价崩盘,该阶段五种不同业务的能源公司均存在大幅波动。2016年中国煤炭行业推动供给侧结构性改革、化解过剩产能,煤炭供给得到有效控制。作为世界上最大的煤炭生产和消费国,该事件对国际煤炭开采行业具有明显的影响。此外,2015年12月12日,《联合国气候变化框架公约》近200个缔约方在巴黎气候变化大会上达成《巴黎协定》。2016年10月5日,《巴黎协定》达到生效所需的两个门槛,并于2016年11月4日正式生效。这些环保协议与指导直接冲击了化石能源行业,由图5可知其对煤炭行业影响最大。最后一个事件为2018年中美贸易紧张,各个能源产业的波动明显加剧。

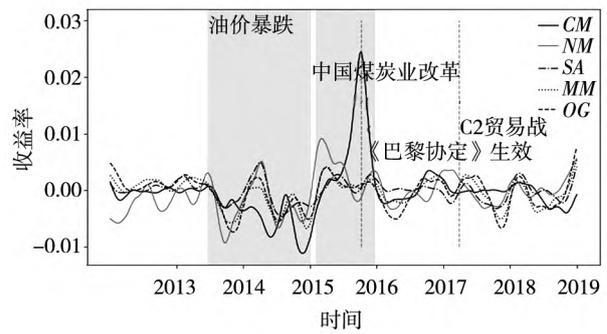


图4 行业平均收益率时序图

Fig. 4 The time-series plot of industry average rate of return  
注:图中各序列为经 Hodrick Prescott 滤波后得到的长期增长趋势。

表3显示了本文研究中81家采矿、采石和油气开采行业公司的股票对数收益率按行业汇总的统计数据。具体而言,增广Dickey-Fuller(ADF)检验表明,所有行业的平均对数收益率均不存在单位根问题,Jarque-Bera(JB)检验表明所有序列的具有非正态性,峰度和偏度显示回报率具有尖峰肥尾的特性。

表2 样本能源公司股票收益率序列的描述性统计

Table 2 Descriptive statistics of the stock returns of sample energy companies

产业分类	标签	股数	占比	均值	标准差	偏度	峰度	ADF 检验	Jarque-Bera 检验
煤炭开采	CM	5	6.2%	-0.000 4	0.04	24.18	854.05	-11.565 ***	53 814 077 ***
非金属矿产开采和采石	NM	8	9.9%	-0.000 2	0.02	1.48	165.46	-13.975 ***	2 014 156 ***
采矿支持活动	SA	12	14.8%	-0.000 5	0.02	0.37	4.74	-12.068 ***	1 695.7 ***
金属矿开采	MM	11	13.6%	-0.000 6	0.04	0.53	42.5	-10.797 ***	132 951 ***
油气开采	OG	45	55.6%	-0.000 5	0.03	0.09	3.62	-12.531 ***	970.01 ***

注:\*\*\*、\*\*、\* 分别表示在1%、5%和10%统计水平上显著。

### 3.2 风险溢出结果分析

本节对样本每个季度拟合风险溢出网络,其中图5展示了2014年第一季度的风险溢出网络图,从图中可以看出风险溢出活动集中于油气开采行业与采矿支持活动行业。接着,对每个季度的溢出网络性质进行分析,从横截面和时变的角度详细分析了基本面和投资者层面的风险溢出强度变化。对于基本面分析,图6展示了2013年第1季度到2019年第4季度能源企业总风险溢出(见式(4))。在图6中,可以清楚地看到,基本面的风险溢出在2014年第3季度达到峰值,并在2016年第4季度之前均处于高位状态。这种变化可能是由于该时期全球能源市场的动荡,极大的提高了能源股票市场风险溢出的可能性。本研究结果也与 Antonakakis

等<sup>[3]</sup>的结果一致:石油价格和能源公司股票价格之间存在显著的波动溢出效应。在能源供给方面,该阶段的美国页岩气革命使得美国的原油产量大幅超出了之前的预期,在需求方面,全球经济在2014年除了美国之外,恢复的幅度实际都略低于预期,尤其欧洲和中国下半年经济增速的放缓,导致了能源等大宗商品需求量的下降。在2018年末到2019年,能源市场基本面风险溢出出现了另一个小高位。在该阶段不但有环保因素驱动的市场波动,也存在地缘政治的影响。国际油价在地缘政治和OPEC减产等因素的推动下震荡上行,于2018年9月份突破85美元,进入10月后受供需面持续宽松和地缘政治事件的影响,急剧下跌。

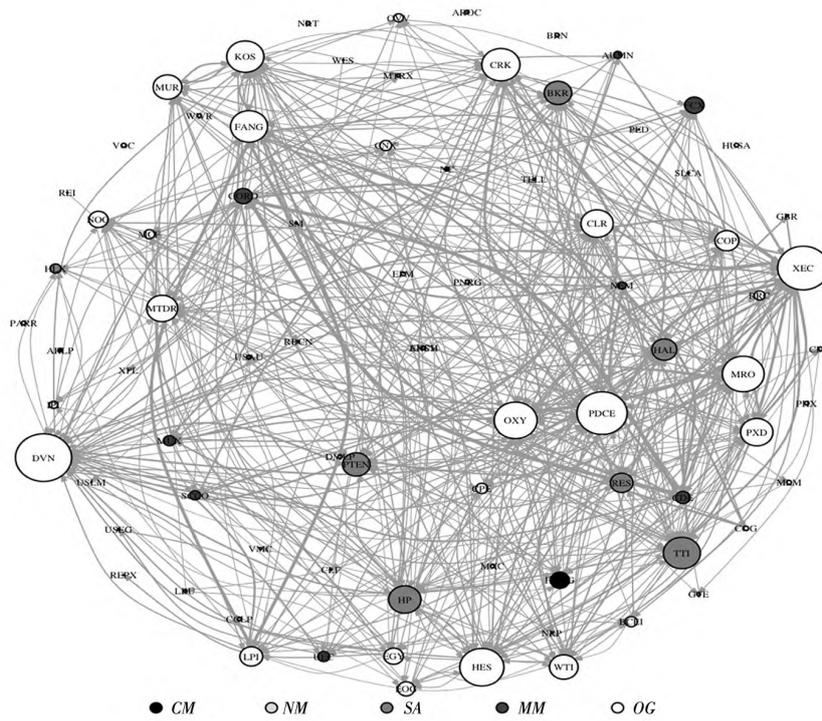


图 5 2014 年第一季度全样本风险溢出网络

Fig.5 Full sample risk spillover network, 2014 Q1

注：图中节点相对大小代表结果总度数的相对数量，连接粗细代表溢出强度大小，该图设置的阈值  $I_{threshold} = 0.1$

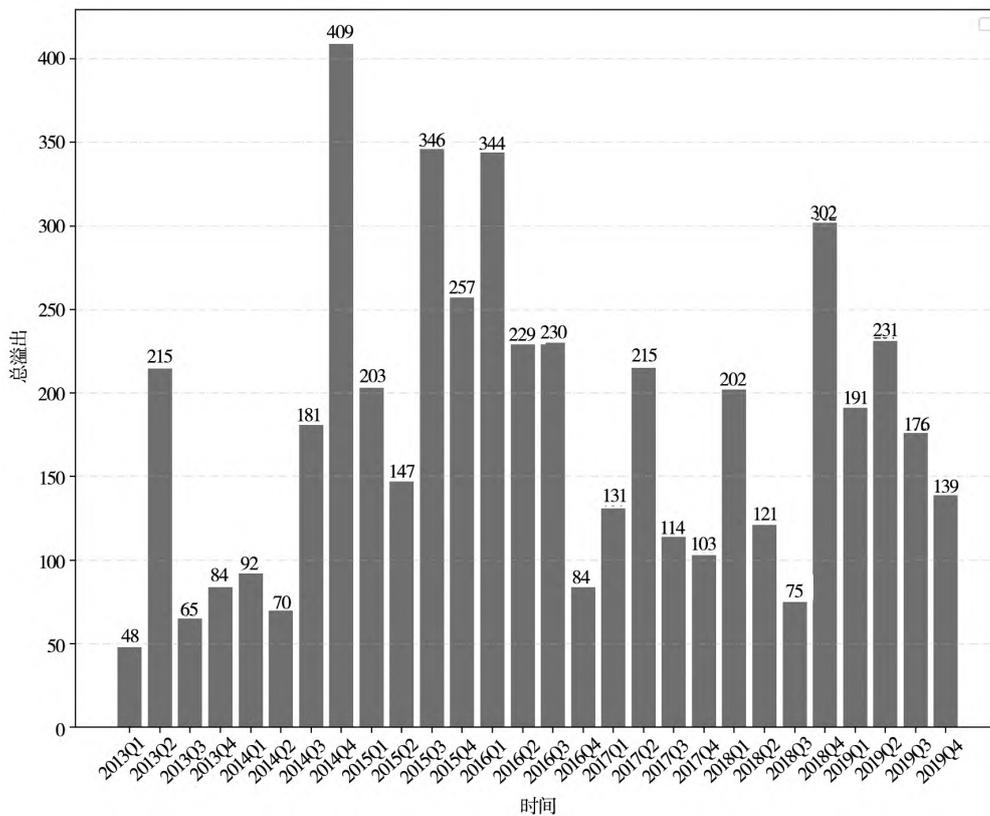


图 6 2013 Q1—2019 Q4 系统风险溢出强度

Fig. 6 Systematic risk spillover intensity 2013 Q1—2019 Q4

根据式(5)与式(6),图7和图8根据能源公司的业务分类描述了能源公司的动态风险溢出.值得注意的是,从事采矿支持活动业务和油气开采的能源企业表现出较大的风险外溢效应和风险承受程度.这可能是因为它们位于能源产业链的上游,广泛的全球业务以及相应的高油价风险敞口使其受油价风险的影响较大.反之,油价风险敞口相对较低的替

代性能源行业,如煤炭开采行业、非金属矿产开采、采石行业和金属矿开采行业的风险外溢与风险承受强度均处于低位.图9显示了不同业务能源公司的净风险溢出,除了开展油气开采业务的企业风险净溢出有明显波动之外,其他业务的能源公司的净溢出均在0处上下波动.表3进一步报告了各行业2013 Q1—2019 Q4 风险外溢效应描述性统计.

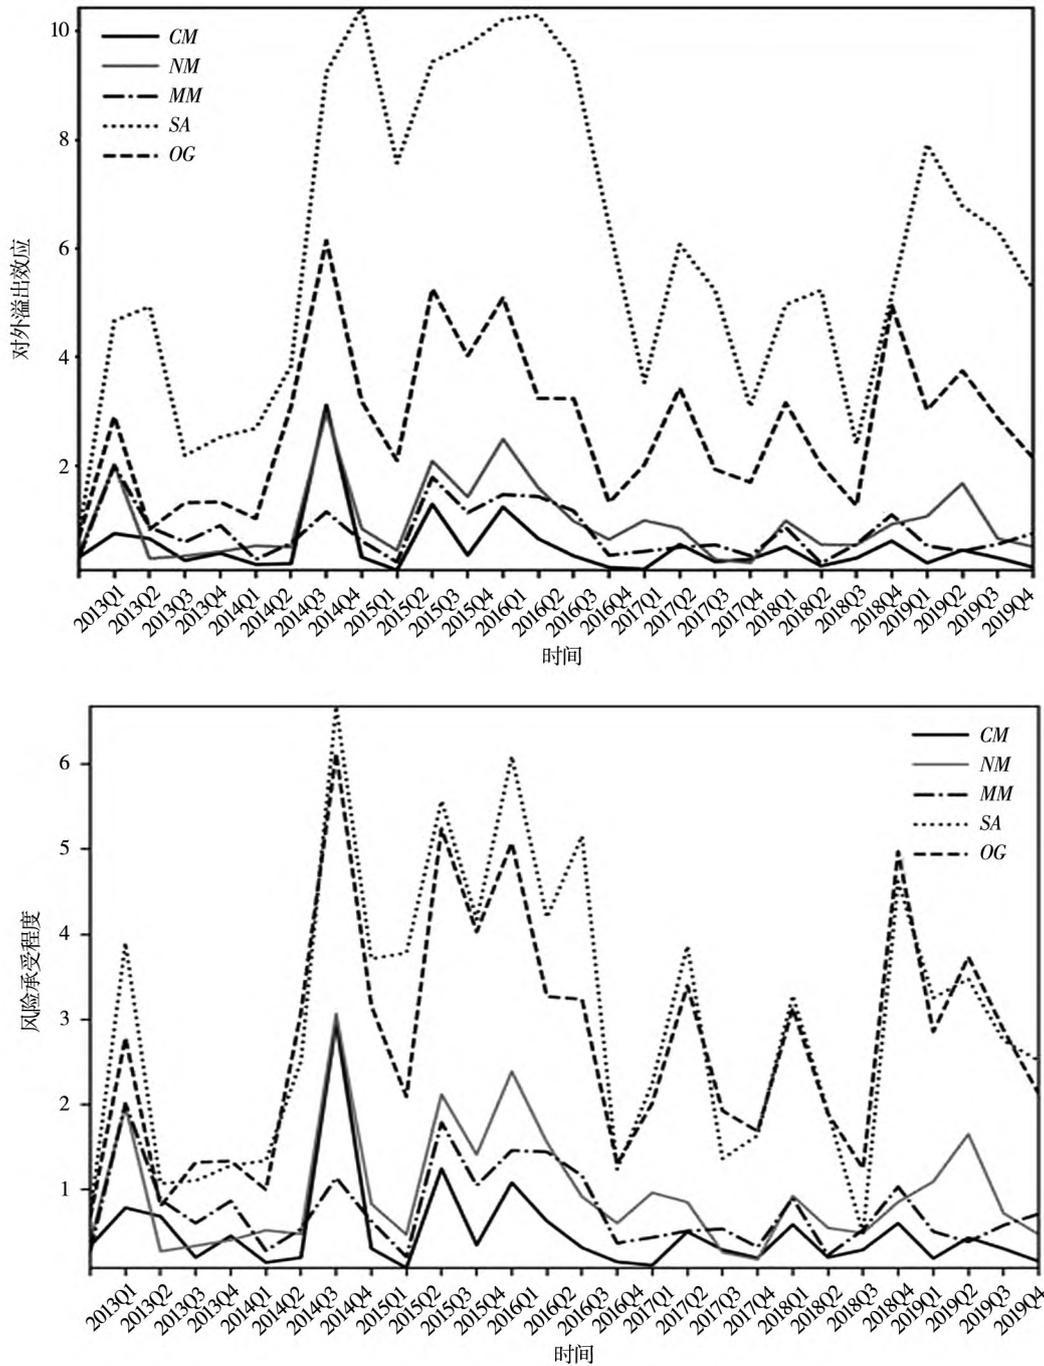


图7 各行业 2013 Q1—2019 Q4 对外溢出效应(左), 风险承受程度(右)

Fig. 7 2013 Q1—2019 Q4 external spillovers (left), risk tolerance level (right) by various industry

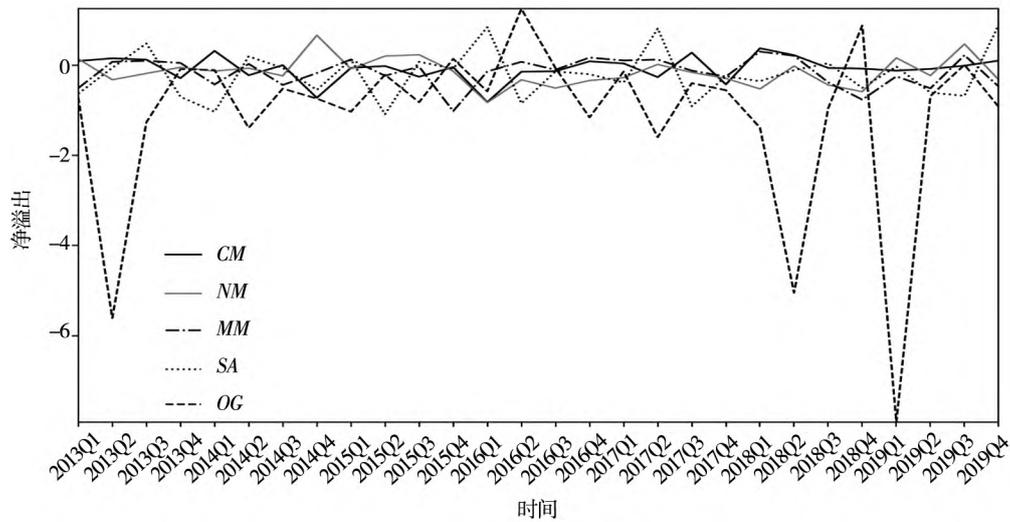


图 8 各行业 2013 Q1—2019 Q4 净风险溢出强度

Fig. 8 2013 Q1—2019 Q4 net spillovers by various industry

表 3 各行业 2013 Q1—2019 Q4 风险外溢效应描述性统计

Table 3 Descriptive statistics of external spillover effects by industry 2013 Q1—2019 Q4

	均值	标准差	最小值	P25	中位数	P75	最大值
CM	0.504	0.594	0.079	0.197	0.316	0.560	3.114
NM	0.971	0.718	0.210	0.441	0.7499	1.335	2.983
MM	0.774	0.475	0.206	0.424	0.585	1.128	2.004
SA	5.940	2.819	0.763	3.089	5.238	8.910	10.427
OG	2.752	1.431	0.682	1.334	2.893	3.384	6.148

为了探索每个能源公司的横截面系统重要性,表 4 给出了 2014 Q1—2019 Q4<sup>⑤</sup> 内每个季度风险溢出最高的 5 家公司的实证结果. 这些公司在某种程度上可以被视为能源市场上的“系统重要性能源公司”,并随着时间的推移“系统重要性能源公司”的排名不断变化,这表明了实时监管的必要性. 此外,表 4 还报告了每个季度 5 家“最具系统重要性”企业的市场资本,其中最具系统

重要性的企业不一定拥有最大的企业规模,而小企业也可以产生显著的风险溢出. 这表明,风险溢出可能受到企业规模以外的驱动因素的影响,如业务复杂性和地理因素等.

通过比较了具有不同业务的公司引发的极端风险溢出,发现几乎所有“系统重要性能源公司”都从事油气开采(OG),其次是从事采矿支持活动的能源公司(SA),这与行业总溢出的结果相一致.

表 4 各季度风险溢出最高的前 5 家公司所属行业,溢出效应强度及企业规模

Table 4 Top 5 companies with the highest risk spillover by various quarter in terms of industry, intensity of spillover effect and firm size

企业名称(行业)	溢出	企业规模	企业名称(行业)	溢出	企业规模
2014 Q1			2014 Q2		
OXY(OG)	3.28	69 275 000	HES(OG)	3.118	41 071 000
DVN(OG)	4.037	52 765 000	CLR(OG)	3.6	14 377 506
HES(OG)	3.291	41 424 000	PXD(OG)	3.439	12 710 000
XEC(OG)	4.251	7 618 635	XEC(OG)	3.187	8 399 007
PDCE(OG)	4.07	2 065 168	LPI(OG)	3.682	3 181 038

⑤ 2013 年季度财务数据缺失,故该部分研究时间区间为 2014 Q1—2019 Q4.

续表 4

Table 4 Continues

企业名称(行业)	溢出	企业规模	企业名称(行业)	溢出	企业规模
2014 Q3			2014 Q4		
COP(OG)	6.665	118 986 000	COP(OG)	12.496	116 539 000
MRO(OG)	9.183	36 700 000	DVN(OG)	13.456	50 637 000
EOG(OG)	9.954	34 500 883	HES(OG)	14.614	38 407 000
XEC(OG)	8.045	8 644 094	MRO(OG)	14.623	35 983 000
SM(OG)	6.531	5 660 746	PTEN(SA)	12.284	5 394 011
2015 Q1			2015 Q2		
COP(OG)	8.229	110 042 000	HAL(SA)	8.312	30 606 000
HES(OG)	9.713	36 101 000	BKR(SA)	7.978	26 018 000
MRO(OG)	8.621	34 736 000	CLR(OG)	7.837	15 409 851
HAL(SA)	9.703	30 587 000	XEC(OG)	6.566	7 568 504
BKR(SA)	8.464	26 926 000	PTEN(SA)	7.123	5 049 528
2015 Q3			2015 Q4		
XEC(OG)	14.26	6 336 362	COP(OG)	10.789	97 484 000
KOS(OG)	11.868	3 105 045	OXY(OG)	9.085	43 409 000
PDCE(OG)	11.661	2 344 310	EOG(OG)	8.999	26 970 470
MTDR(OG)	12.237	1 280 522	HES(OG)	8.265	34 157 000
CPE(OG)	11.835	864 724	PXD(OG)	8.52	15 154 000
2016 Q1			2016 Q2		
COP(OG)	13.459	99 834 000	HAL(SA)	8.696	27 737 000
HAL(SA)	12.102	33 932 000	HES(OG)	7.745	34 234 000
HP(SA)	13.561	7 130 274	DVN(OG)	7.905	27 244 000
AROC(SA)	11.98	2 670 840	HLX(SA)	8.281	2 314 368
MTDR(OG)	11.593	1 164 152	MTDR(OG)	7.664	1 086 088
2016 Q3			2016 Q4		
COP(OG)	8.334	94 284 000	OVV(OG)	4.501	14 653 000
HES(OG)	8.492	34 459 000	SM(OG)	3.616	6 393 511
HAL(SA)	9.281	26 755 000	FANG(OG)	3.275	5 349 680
PTEN(SA)	8.436	3 908 873	XEC(OG)	4.039	4 237 724
FANG(OG)	8.311	3 525 680	CPE(OG)	3.175	2 267 587
2017 Q1			2017 Q2		
EOG(OG)	5.507	29 211 974	HAL(SA)	8.483	25 325 000
DVN(OG)	7.286	26 134 000	MRO(OG)	7.748	24 241 000
CLR(OG)	5.453	13 826 060	CLR(OG)	8.303	13 871 257
CPE(OG)	5.993	2 335 579	GTE(OG)	8.045	1 429 635
LPI(OG)	6.29	1 818 596	RES(SA)	7.725	1 105 885
2017 Q3			2017 Q4		
EOG(OG)	6.15	28 805 305	DVN(OG)	6.244	30 241 000
DVN(OG)	4.649	27 559 000	MRO(OG)	4.984	22 012 000
HES(OG)	6.008	26 600 000	XEC(OG)	3.953	5 042 639
MUR(OG)	4.998	10 192 759	PDCE(OG)	4.932	4 420 390
PDCE(OG)	5.83	4 307 287	CPE(OG)	5.739	2 693 296

续表 4

Table 4 Continues

企业名称(行业)	溢出	企业规模	企业名称(行业)	溢出	企业规模
2018 Q1			2018 Q2		
OXY(OG)	7.673	42 808 000	HES(OG)	4.91	21 464 000
HAL(SA)	7.774	25 191 000	PXD(OG)	6.203	17 449 000
MRO(OG)	9.22	21 634 000	OVV(OG)	5.6	15 128 000
OVV(OG)	8.789	15 110 000	CPE(OG)	6.961	3 507 326
MTDR(OG)	8.835	2 275 705	MTDR(OG)	4.938	2 555 847
2018 Q3			2018 Q4		
PXD(OG)	3.384	42 808 000	COP(OG)	11.216	69 980 000
EOG(OG)	3.637	33 637 736	OXY(OG)	10.941	43 854 000
HES(OG)	3.423	21 467 000	XEC(OG)	11.426	6 062 084
FANG(OG)	4.69	9 806 573	CPE(OG)	11.483	3 979 173
SM(OG)	4.009	6 273 721	NOG(OG)	12.35	1 503 645
2019 Q1			2019 Q2		
FANG(OG)	8.299	22 268 000	OVV(OG)	11.146	21 747 000
MRO(OG)	7.099	21 410 000	DVN(OG)	10.094	16 649 000
MUR(OG)	7.877	11 983 117	SM(OG)	10.473	6 391 939
SM(OG)	7.073	6 286 618	CPE(OG)	8.884	3 915 497
CPE(OG)	7.177	4 108 834	MTDR(OG)	12.228	3 751 451
2019 Q3			2019 Q4		
EOG(OG)	7.169	36 542 269	EOG(OG)	6.356	37 124 608
MRO(OG)	6.871	20 373 000	MRO(OG)	7.771	20 245 000
PXD(OG)	7.718	18 078 000	PXD(OG)	5.758	19 088 000
HP(SA)	6.231	5 897 379	DVN(OG)	5.433	13 717 000
MTDR(OG)	6.86	3 936 639	SM(OG)	5.628	6 292 232

3.3 溢出决定因素分析

下面详细地描述了影响不同业务能源公司风险溢出的显著驱动因素. 根据企业的经营业务对企业进行分类,并分别对风险溢出强度进行回归分析,解释变量的数据来自 OSIRIS 全球上市公司财务分析库.将总资产转换为自然对数形式.限制时间在 2014 年第 1 季度至 2019 年第 4 季度之间的数据,以匹配季度风险溢出强度和季度财务数据.

本研究的实证分析考察了企业特定因素与风险溢出之间的关系,并在面板回归中采用了企业特征和宏观经济解释变量.表 5 给出了面板回归中采用的关键变量的解释.具体而言,采用企业的对外溢出效应 ( $To$ ) 作为被解释变量,企业财务数据作为解释变量,国际原油期货收益率的自然对数,美国季度 GDP 增长率,能源出口增长率和标普 500 股指这 4 个宏观经济变量为控制变量.

表 5 解释变量描述

Table 5 Description of explanatory variables

变量	描述
ROA	每季度各公司的资产回报率
turnover	每季度各公司的资产周转率
current_ratio	每季度各公司的流动比率
ln(TA)	每季度各公司的总资产(将该变量进行对数变换)
Lev	每季度各公司的杠杆率
marpro	每季度各公司的边际收益率
USGDP	美国季度 GDP 增长率
ln(oil)	WTI 原油期货的对数收益率
export	美国季度化石能源出口增长率
SP500_index	标普 500 股票指数

根据表 6 的回归分析结果,对于企业财务变量有以下结论:1) 对于企业财务变量,总资产高的油气开采行业企业往往表现出高风险溢出,而对其他行业则不显著.这意味着,在危机时监管部

门应多关注油气行业的高资产企业,有效阻隔或切断其风险溢出渠道,避免其他行业或该行业的中小企业受到其风险溢出的影响. 2) 单个企业的高财务杠杆总体上不会显著影响能源企业的风险溢出,但会对非金属矿产开采和采石行业以及金属矿开采行业公司的风险溢出有正向促进的作用. 债务杠杆与系统性风险密切相关,这种影响具有顺经济周期性,会增加金融系统的不稳定性,因此关注并管理非金属矿产开采和采石行业以及金属矿开采行业企业的杠杆率有助于弱化系统性风险的冲击. 3) 净资产收益率对每家公司极端风险溢出的影响在不同的行业分类下表现出不同的模式. 具体而言,首先,净资产收益率对煤炭开采行

业风险溢出的驱动作用最为显著且符号为负,其次,对金属矿开采企业也具有显著的负向影响. 这意味着,提高煤炭开采行业以及金属矿开采企业上市公司的盈利能力,有助于控制风险溢出的强度降低以这两个行业为风险源而发生系统性风险的概率. 4) 流动比率和资产周转率都是企业的流动性度量,其中流动比率对金属矿开采企业的风险溢出有显著的积极驱动作用,资产周转率对非金属矿产开采和采石行业的风险溢出存在负向抑制作用. 次贷危机的教训表明,金融杠杆率和资产流动性是系统性风险的源头. 能源企业的资产流动性管理应重点关注金属矿开采行业和非金属矿产开采和采石行业.

表 6 各行业和全市场的回归结果

Table 6 Regression results of various industries and full market

被解释变量	Total	CM	MM	NM	SA	OG
<i>To</i>	(1)	(2)	(3)	(4)	(5)	(6)
<i>ROA</i>	-0.007 9 ** (-2.222 7)	-0.017 6 ** (-2.394 0)	-0.008 3 ** (-2.433 7)	0.021 3 (1.445 1)	0.002 9 (0.216 9)	-0.009 1 (-1.501 0)
<i>turnover</i>	0.019 9 (0.629 9)	0.412 9 (1.627 7)	-0.022 9 (-0.892 7)	-1.605 0 * (-1.759 9)	0.022 3 (0.471 4)	0.177 0 (0.413 6)
<i>current_ratio</i>	0.060 8 (1.557 4)	0.078 2 (0.455 3)	0.148 4 * (1.820 7)	0.034 (0.672 4)	-0.205 4 (-0.706 9)	0.100 4 (0.405 7)
$\ln(TA)$	0.659 2 *** (4.210 1)	0.112 2 (0.276 8)	0.080 4 (0.966 2)	0.361 4 (0.997 0)	0.125 3 (0.199 5)	1.323 6 *** (4.361 3)
<i>lev</i>	-0.415 3 (-0.988 2)	-0.249 9 (-0.259 7)	0.534 8 * (1.826 3)	3.220 9 * (1.726 9)	0.911 0 (0.534 8)	-0.918 2 (-0.946 2)
<i>marpro</i>	0.004 8 * (0.058 0)	0.017 8 ** (2.015 4)	0.001 7 (0.687 9)	-0.002 2 (-0.236 0)	0.000 4 (0.040 3)	0.009 7 ** (2.492 7)
<i>USGDP</i>	0.029 9 (0.710 1)	-0.052 0 (-0.726 7)	-0.034 6 (-0.806 9)	-0.107 3 (-1.247 9)	0.092 5 (0.413 1)	0.080 6 (1.020 2)
$\ln(oil)$	-2.458 8 *** (-10.717 7)	-0.281 0 (-0.680 1)	-0.625 6 *** (-2.720 6)	-1.160 3 *** (-2.616 8)	-3.761 9 *** (-5.920 5)	-3.738 7 *** (-7.687 4)
<i>export</i>	-0.810 8 *** (-5.327 6)	-0.646 0 * (-1.860 3)	-0.219 1 (-1.424 0)	-0.738 1 ** (-2.242 1)	-1.634 9 *** (-3.828 7)	-1.048 6 *** (-3.463 9)
<i>SP500_index</i>	-0.238 0 *** (-7.809 5)	-0.036 4 (-0.703 2)	-0.065 9 ** (-2.147 7)	-0.011 2 (-0.180 5)	-0.309 1 *** (-3.831 5)	-0.393 7 *** (-6.843 2)
$R^2$	0.173 8	0.119 5	0.140 7	0.146 6	0.252 2	0.204 7
<i>F value</i>	26.876 1	1.424 9	3.602 0	2.594 3	8.195 8	16.660 2
观测值数量	1 608	120	240	168	264	528

注: \*\*\*, \*\*, \* 分别表示在 1%、5% 和 10% 统计水平上显著, 括号中的值为显著性检验统计量.

对于宏观经济变量, 国际原油期货价格的对数收益对除煤炭开采行业之外的所有能源公司的

溢出效应均呈现显著的负向影响. 化石能源出口增长率对除了金属矿开采行业的风险溢出均有反

向作用,特别是对采矿支持活动行业.由股票指数所代表的股票市场的波动对金属矿开采行业、采矿支持活动行业以及油气开采行业企业波动溢出均具有显著的负向作用.世界经济的增长会通过改变石油需求量影响国际原油价格和能源出口增长,同时宏观经济形势是影响股票价格走势的基本因素.往往宏观经济形势越好,风险溢出强度越低,这与本文所得的研究结果一致.

本研究结果在某种程度上与 Bianconi 和 Yoshino<sup>[44]</sup> 之前的研究一致,该研究使用了来自 24 个国家的 64 家不可再生能源行业公司的样本,调查了风险决定因素.研究表明,企业特定的决定因素包括公司规模和净资产收益率在解释能源公司的风险对外溢出效应强度上至关重要.更具体地说,能源行业中的风险溢出较大的公司通常规模较大,但资产规模不是唯一的决定因素,小公司也有高溢出风险的可能性,这进一步解释了表 4 中的现象.

### 3.4 预测结果与方法评价

基于非参数因果网络结构学习算法,对目标变量的预测子集进行预选,对各个市场序列进行提前  $H$  阶预测.由于预测中不需要控制间接驱动,所以只需要执行算法的第一步和第二步便能

找到预测工作所需要的决定性驱动变量子集.通过使用上文所述的标准,选择了最优预测集合,然后分别结合无参数模型(CI + KNN)和参数模型(CI + Linear)进行预测(见表 7).

从  $R^2$  来看,CI + KNN 的短期预测效果要优于 CI + Linear,但随着预测步长的增加,CI + Linear 的优势更明显.从平均绝对误差(MAE)与均方误差(MSE)的结果来看,两种方法的预测效果在样本的时间区间较短的数据集中没有明显差别;但随着数据集的扩大,非参数模型 CI + KNN 方法在短期预测中预测精度的优势更明显,而 CI + Linear 方法随着预测步长的增加表现更优.

与纯非参数的最近邻预测相比,该方法结合了非参数模型检测相关变量的优点和基于参数模型预测方差较小的优点,也可以用来更好地理解耦合机理.从不同时间长度的预测结果对比可以看出样本数量在一定程度上影响了预测结果,但不是唯一的影响因素.此外,运用 CI 算法进行预测时具有一定的局限性,对风险传染上游序列比较不友好,这可能由于选择的最长滞后时间过短使得条件因节点集合过小,从而导致预测效果较差.但是在高维的情况下,该缺点的影响较小.

表 7 模型预测精度

Table 7 Model prediction accuracy

预测步长	$R^2$		MAE		MSE	
	CI + KNN	CI + Linear	CI + KNN	CI + Linear	CI + KNN	CI + Linear
$T = T_1, H=1$	0.805 4	0.586 4	0.041 4	0.040 9	0.008 9	0.018 9
$T = T_1, H=2$	0.809 6	0.560 1	0.040 8	0.040 4	0.008 7	0.020 1
$T = T_1, H=3$	0.809 6	0.744 0	0.040 7	0.040 2	0.008 7	0.011 7
$T = T_1, H=4$	0.807 4	0.785 6	0.041 1	0.041 2	0.008 8	0.009 8
$T = T_1, H=5$	0.805 2	0.805 2	0.041 7	0.041 3	0.008 9	0.008 9
$T = T_1, H=6$	0.807 4	0.831 5	0.041 4	0.040 9	0.008 8	0.007 7
$T = T_1, H=7$	0.807 4	0.877 4	0.041 2	0.041 0	0.008 8	0.005 6
$T = T_2, H=1$	0.879 9	0.536 0	0.015 5	0.032 6	0.002 9	0.011 2
$T = T_2, H=2$	0.838 4	0.577 5	0.016 1	0.031 0	0.003 9	0.010 2
$T = T_2, H=3$	0.797 0	0.618 9	0.018 0	0.028 6	0.004 9	0.009 2
$T = T_2, H=4$	0.780 4	0.631 3	0.019 1	0.029 0	0.005 3	0.008 9
$T = T_2, H=5$	0.792 9	0.797 0	0.018 7	0.028 2	0.005 0	0.004 9
$T = T_2, H=6$	0.768 0	0.850 9	0.021 6	0.018 4	0.005 6	0.003 6
$T = T_2, H=7$	0.767 9	0.954 4	0.019 5	0.010 1	0.005 6	0.001 1

注：因果算法以显著性阈值  $I=0.03$ ,  $\lambda=20\%$ , 最大滞后阶数  $\tau_{max}=10$ , 表格中的精度为 81 个样本时间序列的平均预测精度. 使用可决系数  $R^2$  度量预测精度. 测试集和训练集分别占样本总量的 20% 和 80%, 选择两种时间长度, 其中  $T_1$  为 2013-01-03 至 2015-12-31,  $T_2$  为 2013-01-03 至 2017-12-31, 进行多因子预测.

## 4 结束语

本文提出了一种新的非参数高维因果网络构建方法. 通过大量的仿真实验, 证明了该方法在非线性合成数据集中的表现优于传统的 PC 算法, 能有效控制假阳性率并保持较高的真阳性率, 适合中高维度的数据集, 这是对传统方法的维数灾难和过拟合问题的有效解决方案.

首先, 通过运用该方法构建全球 81 家能源公司的风险溢出网络并进行分析, 发现在 2014 年到 2015 年国际能源价格动荡时期, 能源股票市场的风险溢出效应更高, 这表明能源股票市场容易受到全球经济和产业变化的影响. 同时, 通过调查不同业务企业的时变风险溢出, 并发现非油气的能源企业风险溢出较小; 相比之下, 受能源价格深刻影响的油气开采和采矿支持活动企业表现出较高的溢出风险. 此外, 通过调查每个季度风险溢出最高的 5 家企业, 证明了高风险溢出企业在不同时期有所不同并主要集中在油气开采行业. 其次, 利用面板回归对风险溢出的决定因素进行了探索, 并发现 ROA、企业总资产、边际收益、油价收益率、化石能源出口增长率和股指是决定风险溢出的重要因素. 此外, 溢出影响因素呈现行业异质性的表现. 最后, 将该算法应用于多维时间序列预测, 在运行预测模型前用非参数因果网络结构学习算法

进行最优预测子集合的预选, 对比参数模型与非参数模型的预测效果, 结果表明该方法是对传统方法的维数灾难和过拟合问题的有效解决方案. 因果算法预选结合非参数模型的短期预测效果要优于结合参数模型, 但随着预测步长的增加, 参数模型的优势更明显.

对风险管理者, 有以下三点建议: 首先, 在石油价格动荡时期, 需加强关注那些在石油市场中的由于更核心地位和更高风险溢出而表现出更广泛全球业务的公司, 其次, 从实证中发现, 一些小公司也可能在极端风险溢出中发挥重要作用. 最后, 本研究认为通过准确识别行业乃至个体机构的系统重要性, 监管部门应当通过以下建议进一步提高系统性风险的监管精度; 第一, 对承担重要风险吸收功能的能源行业, 加大对其流动性以及金融杠杆率的监控. 第二, 做好对大规模风险溢出行业与企业的监控救助, 加强对其投资资金管理, 帮助其提高自身资金效率稳定风险吸收功能.

未来, 将从以下两方面进一步进行深入探索. 在溢出网络构建上, 加快网络算法运行速度与准确性的同时将该方法扩展到对其他行业的风险溢出分析上来. 在预测模型上, 使得模型的预测步长与精度满足更长期更准确的要求并有助于对极端事件的预测.

## 参考文献:

- [1] 周开国, 季苏楠, 杨海生. 系统性金融风险跨市场传染机制研究——基于金融协调监管视角[J]. 管理科学学报, 2021, 27(7): 1-20.  
Zhou Kaiguo, Ji Sunan, Yang Haisheng. Research on cross market contagion mechanism of systemic financial risk: From the perspective of financial coordination and supervision[J]. Journal of Management Sciences in China, 2021, 27(7): 1-20. (in Chinese)
- [2] 杨子晖, 陈雨恬, 张平森. 股票与外汇市场尾部风险的跨市场传染研究[J]. 管理科学学报, 2020, 23(8): 54-77.  
Yang Zihui, Chen Yutian, Zhang Pingmiao. Cross market contagion of tail risk in stock and foreign exchange markets[J]. Journal of Management Sciences in China, 2020, 23(8): 54-77. (in Chinese)
- [3] Antonakakis N, Cunado J, Filis G, et al. Oil volatility, oil and gas firms and portfolio diversification[J]. Energy Economics, 2018, (70): 499-515.
- [4] Si Deng-Kui, Li Xiao-Lin, Xu Xu-Chuan, et al. The risk spillover effect of the COVID-19 pandemic on energy sector: Evidence from China[J]. Energy Economics, 2021, (102): 105498.
- [5] Chen Ying, Zhu Xuehong, Chen Jinyu. Spillovers and hedging effectiveness of non-ferrous metals and sub-sectoral clean en-

- ergy stocks in time and frequency domain[J]. *Energy Economics*, 2022, (111): 106070.
- [6] Kuck K, Schweikert K. A Markov regime-switching model of crude oil market integration[J]. *Journal of Commodity Markets*, 2017, (6): 16–31.
- [7] Xiong Shi, Chen Weidong. A robust hybrid method using dynamic network analysis and weighted, Mahalanobis distance for modeling systemic risk in the international energy market[J]. *Energy Journal*, 2022, (109): 105954.
- [8] Bing-Yue Liu, Ying Fan, Qiang Ji, et al. High-dimensional CoVaR network connectedness for measuring conditional financial contagion and risk spillovers from oil markets to the G20 stock system[J]. *Energy Economics*, 2022, (105): 105749.
- [9] Ji Q, Fan Y. Evolution of the world crude oil market integration: A graph theory analysis[J]. *Energy Economics*, 2016, (53): 90–100.
- [10] Ji Q, Zhang H-Y, Geng J-B. What drives natural gas prices in the United States?: A directed acyclic graph approach[J]. *Energy Economics*, 2018, (69): 79–88.
- [11] Kerste M, Gerritsen M, Weda J, et al. Systemic risk in the energy sector: Is there need for financial regulation? [J]. *Energy Policy*, 2015, (78): 22–30.
- [12] Wang Gang-Jin, Xie Chi, He Kai-jian, et al. Extreme risk spillover network: Application to financial institutions[J]. *Quantitative Finance*, 2017, 17(9): 1417–1433.
- [13] Chang C L, McAleer M, Tansuchat R. Conditional correlations and volatility spillovers between crude oil and stock index returns[J]. *North American Journal of Economics and Finance*, 2013, (25): 116–138.
- [14] Sun Xiaolei, Wang Jun, Yao Yanzhen, et al. Spillovers among sovereign CDS, stock and commodity markets: A correlation network perspective[J]. *International Review of Financial Analysis*, 2020, (68): 101271.
- [15] Yuan N N, Yang L. Asymmetric risk spillover between financial market uncertainty and the carbon market: A GAS-DCS-Copula approach[J]. *Journal of Cleaner Production*, 2020, (259): 120750.
- [16] Jiang Cuixia, Li Yuqian, Xu Qifa, et al. Measuring risk spillovers from multiple developed stock markets to China: A vine-copula-GARCH-MIDAS model[J]. *International Review of Economics & Finance*, 2021, (75): 386–398.
- [17] Mensi W, Hammoudeh S, Shahzad S J H, et al. Oil and foreign exchange market tail dependence and risk spillovers for MENA, emerging and developed countries: VMD decomposition based Copulas[J]. *Energy Economics*, 2017, (67): 476–495.
- [18] Hanif W, Hernandez J A, Shahzad S J H, et al. Tail dependence risk and spillovers between oil and food prices[J]. *Quarterly Review of Economics and Finance*, 2021, (80): 195–209.
- [19] Rocchi J, Tsui E Y L, Saad D. Emerging interdependence between stock values during financial crashes[J]. *Plos One*, 2017, 12(5): 1–15.
- [20] 沈传河, 王向荣. 金融市场联动形态结构的非线性分析[J]. *管理科学学报*, 2015, 18(2): 66–75.  
Shen Chuanhe, Wang Xiangrong. Nonlinear analysis on the linkage structure of financial market[J]. *Journal of Management Sciences in China*, 2015, 18(2): 66–75. (in Chinese)
- [21] Zhu B, Lin R D, Liu J H. Magnitude and persistence of extreme risk spillovers in the global energy market: A high-dimensional left-tail interdependence perspective[J]. *Energy Economics*, 2020, (89): 104761.
- [22] Fiedor P. Information-theoretic approach to lead-lag effect on financial markets[J]. *European Physical Journal B*, 2014, 87(8): 1–9.
- [23] 韩佳彤, 熊 熊, 李海垚, 等. 基于定单流的主板市场与创业板市场对比[J]. *系统管理学报*, 2019, 28(6): 1106–1115.  
Han Jiatong, Xiong Xiong, Li Haiyao, et al. Comparison between main board market and gem market based on order flow [J]. *Journal of System and Management*, 2019, 28(6): 1106–1115. (in Chinese)
- [24] Balli F, Naeem M A, Shahzad S J H, et al. Spillover network of commodity uncertainties[J]. *Energy Economics*, 2019, (81): 914–927.
- [25] 宫晓莉, 熊 熊. 波动溢出网络视角的金融风险传染研究[J]. *金融研究*, 2020, (5): 39–58.

- Gong Xiaoli, Xiong Xiong. Research on financial risk contagion from the perspective of volatility spillover network[J]. *Financial Research*, 2020, (5): 39–58. (in Chinese)
- [26] Yu L, Zha R, Stafylas D, et al. Dependences and volatility spillovers between the oil and stock markets: New evidence from the Copula and VAR-BEKK-GARCH models[J]. *International Review of Financial Analysis*, 2020, (68): 101280.
- [27] Qiao Z, Chiang T C, Wong W-K. Long-run equilibrium, short-term adjustment, and spillover effects across, Chinese segmented stock markets and the Hong Kong stock market[J]. *Journal of International Financial Markets, Institutions & Money*, 2007, 18(5): 425–437.
- [28] Khalfaoui R, Boutahar M, Boubaker H. Analyzing volatility spillovers and hedging between oil and stock markets: Evidence from wavelet analysis[J]. *Energy Economics*, 2015, (49): 540–549.
- [29] 李合龙, 杨 能, 林楚汉, 等. 我国股票市场行业间波动溢出效应研究——基于改进的 EMD 去噪方法[J]. *系统工程理论与实践*, 2019, 39(9): 2179–2188.
- Li Helong, Yang Neng, Lin Chuhan, et al. Research on the inter industry volatility spillover effect of China's stock market: Based on the improved EMD denoising method[J]. *System Engineering: Theory & Practice*, 2019, 39(9): 2179–2188. (in Chinese)
- [30] Ewing B T, Malik F. Volatility transmission between gold and oil futures under structural breaks[J]. *International Review of Economics & Finance*, 2013, (25): 113–121.
- [31] Schreiber T. Measuring information transfer[J]. *Physical Review Letters*, 2000, 85(2): 461–464.
- [32] Dimpfl T, Peter F J. Analyzing volatility transmission using group transfer entropy[J]. *Energy Economics*, 2018, (75): 368–376.
- [33] Dimpfl T, Peter F J. Using transfer entropy to measure information flows between financial markets[J]. *Studies in Nonlinear Dynamics and Econometrics*, 2013, 17(1): 85–102.
- [34] Ji Q, Bouri E, Roubaud D, et al. Information interdependence among energy, cryptocurrency and major commodity markets [J]. *Energy Economics*, 2019, (81): 1042–1055.
- [35] Verma T S, Pearl J. Probabilistic reasoning in intelligent systems: Networks of plausible inference [J]. *Artificial Intelligence*, 1990, 48(8): 117–124.
- [36] Peter Spirtes, Clark Glymour. An algorithm for fast recovery of sparse causal graphs[J]. *Social Science Computer Review*, 2016, 9(1): 62–72.
- [37] Verma T S, Pearl J. Causal networks: Semantics and expressiveness[J]. *Machine Intelligence and Pattern Recognition*, 1990, (9): 69–76.
- [38] Colombo D I, Maathuis M H. Order-independent constraint-based causal structure learning[J]. *Journal of Machine Learning Research*, 2014, (15): 3741–3782.
- [39] Vejmelka M, Palus M. Inferring the directionality of coupling with conditional mutual information[J]. *Physical, Review E Statistical Nonlinear and Soft Matter Physics*, 2008, 77(2): 026214.
- [40] 卫 敏, 余乐安. 具有最优学习率的 RBF 神经网络及其应用[J]. *管理科学学报*, 2012, 15(4): 54–61.
- Wei Min, Yu Lean. RBF neural network with optimal learning rate and its application[J]. *Journal of Management Sciences in China*, 2012, 15(4): 54–61. (in Chinese)
- [41] Kozachenko L, Leonenko N N. Sample estimate of the entropy of a random vector[J]. *Problemy Peredaci, Informacii*, 1987, 23(2): 9–16.
- [42] Kreuz T, Andrzejak R, Mormann F, et al. Measure profile surrogates: A method to validate the performance of epileptic seizure prediction algorithms[J]. *Physical Review E*, 2004, 69(6): 061915.
- [43] Goría M N, Leonenko N N, Mergel V V, et al. A new class of random vector entropy estimators and its applications in testing statistical hypotheses[J]. *Journal of Nonparametric Statistics*, 2005, 17(3): 277–297.
- [44] Bianconi M, Yoshino J A. Risk factors and value at risk in publicly traded companies of the nonrenewable energy sector [J]. *Energy Economics*, 2014, (45): 19–32.

## Risk spillover analysis and multi factor forecasting based on nonparametric causal network

*WANG Zong-run, ZHOU Ling, MI Yun-long*

Business School, Central South University, Changsha 410083, China

**Abstract:** Risk spillover is the core motive of systemic financial risk generation and evolution. Therefore, it is crucial to investigate the path and intensity of risk spillover. To compensate for the limitations of traditional methods in terms of dimensionality and parameters, this paper combines a nonparametric conditional mutual information test with a causal network structure learning algorithm and proposes a new nonparametric high-dimensional causal network construction method to analyze the dynamic linkages and risk transmission mechanisms of volatility spillovers in the financial system. This paper validates the effectiveness and robustness of the method on a nonlinear synthetic dataset and constructs the optimal prediction subset for multi-factor forecasting of the series based on the causal topology. The model is also applied to construct a volatility spillover network of daily stock returns of 81 global energy companies over the period from January 2013 to December 2019 to measure the dynamic changes in the intensity of risk spillover in both fundamental and investor dimensions and to perform forecasting analysis. In addition, the determinants of risk premia are explored by combining corporate financial data and macroeconomic variables and considering business heterogeneity among firms. The findings show that 1) energy firms in the upstream of the energy chain and those with high oil price exposures exhibit larger risk spillover effects and risk tolerance levels. 2) In addition to firm size, the return on corporate assets, marginal returns and other factors also have impacts on the spillover effect. 3) The risk spillovers of energy companies differ significantly in business and the spillover drivers also differ, which is of important reference value in portfolio decision making, regulatory policy design, etc. 4) Although the causal pre-selection information selection strategy combined with a non-parametric model has better short-term forecasting performance than the one combined with a parametric model, the advantage of the parametric model is more obvious as the forecasting step increases.

**Key words:** causal network; nonparametric causal network structural learning algorithm; risk spillover; multi-factor forecasting