

一种基于文本互信息的金融复杂网络模型

孙延凤 王朝勇

Financial complex network model based on textual mutual information

Sun Yan-Feng Wang Chao-Yong

引用信息 Citation: *Acta Physica Sinica*, 67, 148901 (2018) DOI: 10.7498/aps.67.20172490

在线阅读 View online: <http://dx.doi.org/10.7498/aps.67.20172490>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn/CN/Y2018/V67/I14>

您可能感兴趣的其他文章

Articles you may be interested in

[基于复杂网络动力学模型的无向加权网络节点重要性评估](#)

Evaluation methods of node importance in undirected weighted networks based on complex network dynamics models

物理学报.2018, 67(9): 098901 <http://dx.doi.org/10.7498/aps.67.20172295>

[一种改进的基于信息传播率的复杂网络影响力评估算法](#)

An improved evaluating method of node spreading influence in complex network based on information spreading probability

物理学报.2017, 66(20): 208901 <http://dx.doi.org/10.7498/aps.66.208901>

[多层单向耦合星形网络的特征值谱及同步能力分析](#)

Synchronizability and eigenvalues of multilayer star networks through unidirectionally coupling

物理学报.2017, 66(18): 188901 <http://dx.doi.org/10.7498/aps.66.188901>

[一个描述金融投资项目演化的量子力学状态方程](#)

Quantum mechanical state equation for describing evolution of projects of financial investment

物理学报.2014, 63(9): 098901 <http://dx.doi.org/10.7498/aps.63.098901>

[基于节点拓扑特征的中国基金公司共持网络持股行为波动相关性](#)

Correlation of the holding behaviour of the holding-based network of Chinese fund management companies based on the node topological characteristics

物理学报.2014, 63(4): 048901 <http://dx.doi.org/10.7498/aps.63.048901>

一种基于文本互信息的金融复杂网络模型*

孙延风¹⁾ 王朝勇^{2)†}

1) (吉林大学计算机科学与技术学院, 长春 130012)

2) (吉林工程技术师范学院信息工程学院, 长春 130021)

(2017年11月21日收到; 2018年3月22日收到修改稿)

复杂网络能够解决许多金融问题, 能够发现金融市场的拓扑结构特征, 反映不同金融主体之间的相互依赖关系. 相关性度量在金融复杂网络构建中至关重要. 通过将多元金融时间序列符号化, 借鉴文本特征提取以及信息论的方法, 定义了一种基于文本互信息的相关系数. 为检验方法的有效性, 分别构建了基于不同相关系数 (Pearson 和文本互信息) 和不同网络缩减方法 (阈值和最小生成树) 的 4 个金融复杂网络模型. 在阈值网络中提出了使用分位数来确定阈值的方法, 将相关系数 6 等分, 取第 4 部分的中点作为阈值, 此时基于 Pearson 和文本互信息的阈值模型将会有相近的边数, 有利于这两种模型的对比. 数据使用了沪深两地证券市场地区指数收盘价, 时间从 2006 年 1 月 4 日至 2016 年 12 月 30 日, 共计 2673 个交易日. 从网络节点相关性看, 基于文本互信息的方法能够体现出大约 20% 的非线性相关关系; 在网络整体拓扑指标上, 本文计算了 4 种指标, 结果显示能够使所保留的节点联系更为紧密, 有效提高保留节点的重要性以及挖掘出更好的社区结构; 最后, 计算了阈值网络的动态指标, 将数据按年分别构建网络, 缩减方法只用了阈值方法, 结果显示本文提出的方法在小世界动态和网络度中心性等指标上能够成功捕捉到样本区间内存在的两次异常波动. 此外, 本文构建的地区金融网络具有服从幂律分布、动态稳定性、一些经济欠发达地区在金融地区网络中占据重要地位等特性.

关键词: 经济物理学, 文本互信息, 最小生成树, 阈值网络

PACS: 89.65.Gh, 89.70.Cf, 89.75.Fb

DOI: 10.7498/aps.67.20172490

1 引言

统计物理方法有助于从系统复杂性的角度理解社会和经济问题^[1], 解释复杂系统随时间演化的过程. 金融物理学 (econophysics) 则运用统计物理方法来研究金融复杂系统中各个领域的相关问题^[2-4]. 由于受到政治、战争、宏观经济以及社会舆论等多种因素的影响, 至今没有一个完美的理论能完全揭示出金融系统整体的运行规律. 现今金融系统中的很多研究都是基于各种假说, 比如套利定价理论 (arbitrage pricing theory, APT), 有效市场假说 (efficient markets hypothesis, EMH)^[5,6] 等. 借助于复杂网络建模思想, 可以在较少市场假说下, 实现对整个金融系统中各种变量相互关系的研究,

能够从整体上研究金融主体之间的相互依赖性, 反映金融市场整体的拓扑结构^[7].

许多金融市场问题都可以使用复杂网络方法建模, 常见的有股票市场^[8-14]、外汇市场^[15-17]、银行信贷关系^[18]、信用卡市场^[19]、期货市场^[20,21]以及房地产市场^[22-24]等. 数据上使用较多的是低频数据 (主要是每日数据), 也有些研究使用了高频数据^[17,25-27]. 金融复杂网络模型主要有最小生成树 (minimal spanning trees, MST)^[14-16]、最大生成树 (maximal spanning trees)^[28]、平面极大过滤图 (planar maximally filtered graph, PMFG)^[24]、阈值网络 (threshold networks, TN)^[11,29,30]、随机矩阵理论 (random matrix theory, RMT)^[8,23,31]、差分网络 (differential network) 等^[32]. 通过选择不同

* 吉林省择优资助留学回国科研人员创新创业项目 (批准号: 201523) 资助的课题.

† 通信作者. E-mail: cywang@jleu.edu.cn

的网络节点、不同的数据类型、不同边的连接方式(有向^[17]或无向)构造出不同的金融复杂网络模型,研究各种金融拓扑结构、计算金融风险统计特征,用来解决不同的金融问题,构建金融投资组合以及度量金融系统风险大小^[15]等。

金融复杂网络建模中一个重要的步骤是计算节点之间的相关矩阵. 一种方法是使用 Pearson 相关系数. Mantegna^[9]在1999年将其用于美国股票市场,并构造了一个 MST 网络. 此后 Pearson 相关系数被广泛应用于金融复杂网络中, Wang 和 Xie^[24]使用 Pearson 相关系数构造了 20 个国家不动产证券市场的三个网络模型,即 MST, HT 和 PMFG; Wang 等^[14]则将 Pearson 相关系数用于 57 个股票市场动态网络的构建. Pearson 相关系数是一种线性相关系数,然而金融系统具有典型的非线性特征,为此一些学者在计算相关矩阵时使用节点间的互信息 (mutual information, MI) 来度量节点之间的相关性^[15,17,33]. 互信息以信息论^[34]为基础,能够度量两个不同序列之间包含多少相同的信息,反映两个变量序列之间的非线性相关关系,因此在金融复杂网络中得到了广泛应用,并在此基础上发展了很多其他度量非线性相关的方法,比如互信息率 (mutual information rate, MIR)^[33]、偏互信息 (partial mutual information, PMI)^[30,35]等。

Fiedor^[33]引入互信息和互信息率作为相似性度量指标,用来替代 Pearson 相关系数,使用 Lempel-Ziv 复杂度^[36]来估计 MI 和 MIR. 网络缩减模型采用的是 MST 和 PMFG 模型,并应用于纽约证券交易所 100 指数 (NYSE100) 的 91 家企业在 2003—2013 年的日收盘数据. 为检验替换效果,采用了平均最短路径 (average shortest path, ASP) 等指标,从节点、聚类以及网络等三个层面与 Pearson 相关性进行了对比. 结果显示 MI 具有比 Pearson 相关性更优秀的特征,但 MIR 效果差一些. You 等^[35]对上海股票市场的复杂网络的非线性相关问题进行了讨论,使用 PMI 度量节点间的相关性,并与 Pearson 相关性做了对比. 假定样本服从 Dirichlet 分布,使用熵 (entropy) 的 Schurmann-Grassberger 来估计 PMI,分别采用 MST 和 PMSG 模型为网络缩减方法. 使用 Pearson 相关性、MI 和 PMI 作为相关性度量方法,得到 6 组不同的网络. 从相关性、经济部门结构、节点度分布以及网络中重要程度不同的股票 (从节点度大小的角度度量) 在经济上每股收益率的变化等方面进行了对比研

究. Fiedor 和 Holda^[15]将 MI 用于外汇市场,使用 Lempel-Ziv 算法估计 MI,采用了 MST 和 PMFG 模型,分析了汇率之间的非线性相互依存关系. 认为根据熵率的不同,不同汇率变化的可预测性是不同的,因此汇率投资组合中不但要考察 VaR 等风险指标,还要考察可预测性. 此外,可以通过复杂网络中节点的远近直接观察到两种货币之间的相关性 (或互信息) 的大小关系,相关性越低则风险越小,越适合作为投资组合的组成部分. 与其他在一维空间使用 Lempel-Ziv 复杂度的文献不同, Fiedor^[13]为计算互信息率,将 Lempel-Ziv 复杂度扩展到多维信号,来研究不同金融工具序列之间的高阶相关性,然后将其转换成欧几里德度量,采用 MST 和 PMFG 模型,以便找到网络建模金融市场的合适的拓扑结构. 结果表明这种方法会导致与大多数研究中使用基于相关的方法不同的结果.

参考文献^[33, 35]在计算互信息时假定样本服从 Dirichlet 分布,并且需要将样本离散成几个不同的状态 (比如人为分成 4 个部分或 8 个部分^[33]). 本文借鉴文本特征提取的互信息方法以及时间序列符号化方法,构造一个简单的非线性相关性度量方法,该方法不再假定样本服从 Dirichlet 分布,也不进行人为的离散化. 为检验该方法的效果,将其用于中国沪深两地证券市场的地区指数收盘价数据集,建立地区金融网络模型,分别进行静态与动态分析,考察所建立模型的拓扑性质.

本文安排如下: 第 2 节完整叙述本文的模型,建立 4 个不同的地区金融网络模型; 第 3 节介绍使用的数据来源、数据前期处理以及数据相关的统计特征以及地区金融网络拓扑特征等; 第 4 节从节点相关性、网络拓扑指标、度分布的幂律检验以及动态网络拓扑指标等多个不同的角度对本文提出的方法进行数值检验,并与 Pearson 相关系数对比; 第 5 节进行概括性的总结与展望.

2 地区金融网络模型

本节在金融时间序列符号化基础上,使用改造的文本互信息方法计算相关系数,随后建立 4 个金融复杂网络模型. 这些模型的相同点是节点都是地区指数,节点间的相互链接都用相关性表示,相邻边的权值都用相关系数的大小表示; 不同之处在于使用的网络精简方法以及获得相关系数的方法不同.

2.1 基于文本互信息的相关系数

互信息在文本特征选择中有广泛的应用^[37], 互信息能够度量两个随机变量的相互依赖性. 如果设文本特征项为 t , 类别为 TC, 则它们之间的互信息可定义为

$$I(t, TC) = \ln \left(\frac{p(t, TC)}{p(t)p(TC)} \right) = \ln \left(\frac{p(t|TC)}{p(t)} \right), \quad (1)$$

其中 $p(t, TC)$ 为文本特征项 t 和类别 TC 的联合分布, $p(t)$ 和 $p(TC)$ 分别是特征项 t 和类别 TC 的边缘分布. 本文将文本互信息公式改造后应用到两个金融时间序列的相关性度量中.

为此需要将时间序列符号化, 进一步可以估计出符号序列的统计信息, 计算出两个序列之间互信息的大小. 符号化的处理方法在很多金融复杂网络相关文献中被广泛使用, 并已取得了良好的效果^[38,39]. 对于一个金融时间序列, 可以利用(2)式将其符号化,

$$s_t = \begin{cases} +r_t \geq 0, \\ -r_t < 0, \end{cases} \quad (2)$$

其中 s_t 为第 t 天符号化序列, r_t 为第 t 天地区指数收盘价的对数收益率.

对于两个金融时间序列 X, Y , 在给定的第 t 天, 可以定义4种模式, 它们分别是: $\{+, +\}\{-, -\}\{+, -\}\{-, +\}$, 统计这4种模式在给定区间内的总数, 分别记为 A, B, C, D . 则可利用(3)式计算这两个金融时间序列在给定区间内的互信息相关性:

$$I(X, Y) = \ln \left[\frac{(A + D) \times N}{(A + B + D)(A + C + D)} \right], \quad (3)$$

其中 $N = A + B + C + D$.

由(3)式可见, 两个序列的互信息是完全对称的, 即 $I(X, Y) = I(Y, X)$; 互信息越大, 两个序列同涨同跌的可能性越大, 两个序列的相关程度也越大; 当两个序列完全相关时, $B = C = 0, N = A + D$, 则 $I = 1$; 两个序列完全无关时 $p(t, TC) = p(t)p(TC), A + D = 0$ 则 $I = 0$.

但(3)式定义的互信息相关系数不能满足距离的3个条件. 本文采用很多金融复杂网络文献普遍使用的方法^[9]将其转化为距离:

$$d = \sqrt{2(1 - I)}, \quad (4)$$

此时 $0 \leq d \leq 2$, 并且满足距离的3个条件.

2.2 4个地区金融网络模型

为考察 MI 相关系数在构建地区金融网络方面的优势, 将其与使用 Pearson 相关系数的相同金融网络从相关性分析、网络拓扑指标数值大小、度的幂律分布以及动态网络特性等几个方面进行了比较.

使用不同的相关系数(线性的 Pearson 方法, 非线性的 MI 方法)和网络精简方式(TN 和 MST)构建4个金融地区指数的复杂网络, 见表1. 这4个地区金融网络模型都是无向的、加权的复杂网络.

表1 不同相关系数和精简方式构建的模型
Table 1. Models created with different correlation coefficient and different simplified method.

| | TN | MST |
|---------|---------|---------|
| MI | Model 1 | Model 3 |
| Pearson | Model 2 | Model 4 |

3 检验数据

为检验4个地区金融网络模型, 使用中国沪深两地证券市场的真实数据. 数据采集于深圳市财富趋势科技股份有限公司的通达信 Windows 版软件^[40]中的地区指数收盘价, 共32个地区(不包括港澳台, 深圳单独算一个地区), 时间区间从2006年1月4日到2016年12月30日, 共计2673个交易日.

采用这组数据的优势在于: 1) 每个地区都涵盖了本地区沪深上市公司的A股、创业板、中小板等板块, 这些地区指数基本上代表了沪深两地全部的上市公司, 能够较全面地刻画中国沪深证券市场的情况, 反映证券市场整体的运行信息; 2) 这些地区指数在所选时间段内几乎没有因停牌等原因造成的数据缺失或异常(除了贵州板块指数数据在2006年5月19日至2006年5月24日数据异常, 处理方法是将其区间内数据全部使用前一日即2006年5月18日的数据代替), 不需要对数据进行人为的删除或更新; 3) 与其他文献不同的是, 本文把证券市场按地区划分, 并从复杂网络的角度研究证券市场的地区性质, 从而得出一些关于地区板块指数的结论.

为消除个别数据异常波动造成的影响, 使数据更加平稳, 采用沪深股票市场地区板块指数的对数

收益率,

$$r_t = \ln(p_t/p_{t-1}), \quad (5)$$

其中 r_t 为第 t 天的日对数收益率; p_t 为地区板块指数在第 t 天的日收盘价.

网络的精简方式分别使用 TN 和 MST, 这两种方法都能够过滤掉一些次要信息, 便于对金融网络中最重要的信息进行分析, 有助于理解金融市场的动态拓扑特征.

MST 在最大程度上对网络精简, 只研究金融

网络中最相关的依赖关系, 降低了金融网络模型的复杂度, 更有利于大型网络分析, 对于金融市场的大量数据来说有重要意义.

在构建 TN 时, 一项重要的工作是选择阈值, 通常的做法是人为给定阈值, 也有学者使用均值和方差来确定阈值, 或者绘制经验密度函数^[11,41]. 本文采用分位数的方法确定阈值: 将相关系数(变成距离 d 并去掉 0 后)在其最小值和最大值的区间内若干等分, 然后取其中一个区间的 midpoint 为阈值. 经




图 1 Model 1 的网络拓扑图 (阈值为 0.91)

Fig. 1. Network topology of Model1 (threshold is 0.91).




图 2 Model 2 的网络拓扑图 (阈值为 0.61)

Fig. 2. Network topology of Model 2 (threshold is 0.61).

通过对地区指数数据的不同时间段与不同相关系数的反复测算,发现将数据6等分并取第4个区间的中点为阈值较为合理,大约能够涵盖25%的数据值,这比Brida和Risso^[41]建议覆盖50%的累积分布值略少.这样选择的阈值,能够使得所保留的边数适中,保留较为重要的节点连接和便于观察的网络拓扑结构,得到相应的统计指标,更为重要的是能够使得MI和Pearson方法得到的连边数最为接近,便于两种方法的对比.

图1—图4给出了4种网络模型Model 1—Model 4在整个数据区间的网络拓扑图.从4个

模型的网络拓扑图可以看出,度值大的结点在网络中占较少的部分,但对金融网络中的多数节点都有较大影响.

在Model 1和Model 2中,阈值的确定采用上面提出的分位数方法,此时两个模型的连边数分别为117和116条,较为接近,便于对比两种方法的拓扑结构与拓扑指标.

对于TN网络(图1和图2),MI和Pearson方法在节点度上大于21的节点共有4个,并且这4个节点完全相同,只是在北京板块和西藏板块的节点度上有所不同:北京板块的度值在MI中为25,在




图3 Model 3的网络拓扑图
Fig. 3. Network topology of Model 3.




图4 Model 4的网络拓扑图
Fig. 4. Network topology of Model 4.

Pearson 中为 22; 西藏板块在 MI 中为 22, 而 Pearson 中为 26. MI 方法提高了北京板块的度, 降低了西藏板块的度, 本文认为这种改变应该更合理一些. 在 MST 网络中(图 3 和图 4), 两种相关系数模型中, 度大于 6 的节点共有 3 个, 黑龙江(度值为 7)和辽宁(度值为 7)板块相同, 度的大小也相近. 另外的节点在 Model 3 中为湖北板块(度值为 7), 而 Model 4 中为山东板块(度值为 9), 存在一些差异.

在以地区指数为节点的 4 个金融复杂网络模型中, 从度的大小看, 西藏、贵州、青海等西部板块以及黑龙江、辽宁等东北板块占据了重要的地位, 说明在中国的股票市场中, 经济欠发达地区的股票有重要的地位, 这一点在后面逐年的复杂网络中得到了进一步的证实. 分析其中的原因发现, 这些地区中有有如 600519 贵州茅台、600338 西藏珠峰、600117 西宁特钢等活跃度较高的上市公司, 因此从证券投资的角度看, 重视这些地区的上市公司的投资将会对收益产生一定的影响.

为反映中国股票市场整体状况, 考察上述数据区间对应的上证综指收盘价, 因为其能够代表整个市场的运行状态. 这期间(即从 2006 年 1 月 4 日—2016 年 12 月 30 日)包含了 2 次较大的波动: 2007 年 10 月 16 日附近(最高 6092.06 点)以及 2015 年 6 月 12 日附近(最高 5166.35 点). 接下来在 4.4 节动态网络逐年对比分析中将重点考察不同模型对这两次大幅波动的捕捉能力.

4 结果分析

使用上节的地区板块指数数据以及第 2 节建立的 4 个地区金融网络模型(Model 1—Model 4), 本节从节点的相关性分析、网络整体拓扑指标、度的幂律分布检测以及动态网络拓扑特征(这里只讨论 TN 网络) 4 个方面分别讨论以 MI 与 Pearson 为相关系数的地区金融网络的优缺点.

表 3 MI 和 Pearson 相关系数的指标
Table 3. The index of MI and Pearson correlation coefficient.

| | AWD | NBC | WSCC | NCC | Total triangles | NOC | Modularity |
|---------|-------|--------|--------|--------|-----------------|-----|------------|
| Model 1 | 7.744 | 0.3738 | 0.8465 | 0.3605 | 191 | 2 | 0.070 |
| Model 2 | 5.319 | 0.2679 | 0.8415 | 0.2963 | 169 | 3 | 0.026 |
| Model 3 | 1.200 | 0.7102 | 0 | 0 | 0 | 5 | 0.670 |
| Model 4 | 0.854 | 0.7204 | 0 | 0 | 0 | 6 | 0.653 |

4.1 节点相关性分析

为对比使用 MI 与 Pearson 相关系数的不同效果, 首先计算 4 个地区金融网络模型中每个节点的接近度(closeness)中心性, 介值(betweenness)中心性, 平均最短路径长度(average shortest path length, ASPL), 特征中心性(eigencen)等 4 个指标; 然后计算 TN 网络即 Model 1 和 Model 2 的节点序列在上述 4 个指标上的相关度, 结果见表 2 第 1 行; 最后计算 MST 网络即 Model 3 和 Model 4 的节点序列在上述 4 个指标上的相关度, 结果见表 2 第 2 行.

从表 2 可见, 除了 MST (Model 3 与 Model 4) 的 ASPL 相关度为 0.4358, 其他都在 0.76—0.94 之间, 这说明本文提出的文本互信息方法大约体现了 20% 左右的非线性相关关系. 与 You 等^[35]的结果很相近, 而与 Fiedor^[33]的 30% 相比少了一些(文献^[33]的结果中也存在 0.8 以上的相关度). 产生这种现象的原因我们认为与数据有关, You 等^[35]使用的数据是上交所上市公司的数据, 与本文的数据源很相近, 而 Fiedor^[33]使用的数据是相对成熟的市场, 即纽交所(New York Stock Exchange)的数据.

表 2 节点相关性分析
Table 2. Correlation analysis for nodes.

| 相关度 | Closeness | Betweenness | ASPL | Eigencen |
|-------------------|-----------|-------------|--------|----------|
| Model 1 与 Model 2 | 0.9485 | 0.8196 | 0.9253 | 0.9336 |
| Model 3 与 Model 4 | 0.8255 | 0.8190 | 0.4358 | 0.7637 |

4.2 网络拓扑指标

本小节从网络的层面对 4 个模型的拓扑指标进行对比. 分别计算不同网络的平均加权度、介值中心性、网络聚类系数以及模块度等, 计算结果见表 3.

平均加权度 (average weighted degree, AWD) 是一种度量网络中节点的平均重要程度的指标, 考虑了每个边权重大小的不同, 计算时将边的权重求和, 然后除以节点数. 不论 TN (Model 1) 还是 MST (Model 3) 网络, 使用 MI 相关系数所保留的节点的平均加权度均高于 Pearson 相关系数, 体现了 MI 相关系数在保留重要节点上优于 Pearson 相关系数.

网络介值中心性 (network betweenness centralization, NBC) 为金融网络中所有最短路径中经过该节点的路径的数目占最短路径总数的比例, 是衡量网络节点作为桥梁中介程度的指标, 介值数高的节点 (地区指数) 在金融网络信息传输中起着至关重要的作用. 从表 3 可见, MST 中 MI (Model 3) 和 Pearson (Model 4) 的 NBC 值都是 0.7 左右, 但 TN 中, MI (Model 1) 的值要比 Pearson (Model 2) 的值高出 30% 左右, 说明对于 TN 网络而言, MI 能够有效提高所保留节点的介值重要性.

聚类系数体现了节点的集聚程度. 在 Pajek 软件 [42] 中有加权和不加权两种: 网络的 Watts-Strogatz 聚类系数 (Watts-Strogatz clustering coefficient, WSCC) 是所有节点的聚类系数的非加权平均; 网络集聚系数 (network clustering coefficient, NCC) 是所有节点的聚类系数的加权平均.

从表 3 可见, 在 TN 网络中 (Model 1 和 Model 2), 地区指数的 WSCC 都为 0.84 左右, 而 NCC 分别为 0.36 和 0.296, 数值较大, 说明我国上市公司地区指数网络的集聚程度较高, 具有小世界网络的集聚特征. 从三角节点数量上看, 在使用的边差不多的情况下, MI (Model 1) 提取出的三角数量比 Pearson (Model 2) 多出 20 多个, 说明 MI 能够提高节点的质量.

从模块化程度上看, 模块度 (modularity) 能测量社区划分的质量, 是一种衡量网络社区结构强度的方法. 本文采用了 Blondel 等 [43] 的算法计算模块度, 参数为默认的 (随机, 使用边的权值, Resolution 取 1). 在 MST 网络中模块度均大于 0.6, 划分质量较好, 描述了网络中强大的社区结构和明确的社区划分 [44]; 而 TN 网络的模块度均小于 0.1, 划分质量差一些. 从数量上看, 不论是 MST 网络还是 TN 网络, MI 均大于 Pearson, 这一点在 TN 网络中尤其明显, 说明 MI 方法更能挖掘出更好的社区结构. 此外, 从社区结构的数量 (number of communities, NOC) 看, 在相同的情况下, MI 方法 (Model 1 和 Model 3) 均略少于 Pearson 方法 (Model 2 和 Model 4), 说明 MI 方法保留的节点关系更为密切, 联系更为紧密.




图 5 双对数坐标下度分布及线性拟合图
Fig. 5. Degree distribution in LogLog and their linear fitting.

4.3 度的幂律分布

对于给定的数据和网络结构, 每个节点的度都是固定的. 本节使用 Clauset 等^[45]的方法来考察节点度的分布情况.

Model 1—Model 4 这4种网络的双对数坐标下的节点度分布以及相应的线性拟合见图5, 从图中可以看出明显的幂律分布特征.

4.4 动态指标对比

与前面几节中使用整个数据集构建网络不同的是, 本节将数据按年度划分, 分别构建11个网络. 由于MST网络过于精简, 本小节将只考虑TN网络, 分别使用MI和Pearson为相关系数, 分别对11个年份数据构造金融网络, 阈值均采用上面提到的分位数统计方法, 主要考虑MI和Pearson两种方法的可比性(连边数最为接近). 分别从小世界动态指标、网络度中心性以及Jaccard指标等3组动态指标上考察捕捉2007年和2015年上证综指两次大幅波动的能力.

小世界动态指标(dynamics of the small-world)定义为网络平均最短路径长度与网络聚类系数之间的比值^[46]. 图6中MI(实线)小世界动态指标的值在2015年达到极值, 并且在2007年也出现了一个局部峰值. 与其对比的是图6中Pearson(虚线)小世界动态指标峰值出现在2012年, 2015年次之. 这两个图的对比说明对于异常年份的反应能力MI比Pearson有所提高.

逐年的网络度中心性(network degree centralization)指标如图7所示, 可以看出, MI(实线)在




图6 TN网络的小世界动态指标
Fig. 6. Dynamics of the small-world of TN.

2015年达到次高峰值, 2007年也出现了局部峰值; 而Pearson(虚线)则在2007年没有出现峰值. 此外, 考察每年节点度的大小, MI和Pearson两种方法中, 贵州板块除了2015年度较小外(MI为13, Pearson为15), 其他年度均具有较大的度值(30左右), 说明近些年贵州板块发挥了重要的作用.

Jaccard指标^[47]能够识别动态TN的稳定性, 2个阈值网络之间的Jaccard指标定义为^[29]

$$J = \frac{N_1}{N - N_1}, \quad (6)$$

其中 N_1 是两个阈值网络间相同节点对的连接数目; N 是这两个阈值网络总的连接数目.

Jaccard指标计算结果如图8所示, MI(实线)的平均值为0.397(2012—2013年间的最小值为0.292, 这段时间上证综指波动幅度较小). Pearson(虚线)的平均值为0.519. 从Jaccard指标看, MI和Pearson模型的Jaccard值多数都在0.3以上^[29], 说明地区指数数据具有网络的动态稳定性^[47].




图7 TN网络的网络度中心性指标
Fig. 7. Network degree centralization of TN.




图8 TN网络的Jaccard指标
Fig. 8. Jaccard index of TN.

5 结 论

复杂网络被广泛地应用于金融领域,能够反映金融市场整体的拓扑结构、动态运行规律以及金融主体之间的相互依赖关系. 本文使用文本互信息方法来度量地区金融指数节点的相关性,分别构建了MST与TN网络,并将其与Pearson相关系数的网络从节点相关度、网络拓扑指标数值大小、度分布的幂律检验以及动态网络特征等方面进行了对比,数值结果表明文本互信息方法在多数指标上优于Pearson方法. 1) 在金融网络中引入基于文本互信息的相关性度量方法,计算时不需要将样本人为离散化成几个不同的状态,也不需要假设样本服从Dirichlet分布; 2) 在阈值网络中提出使用分位数来确定阈值的方法,考虑到两种方法对比的实际需要,本文将数据6等分并取第4个区间的中点为阈值; 3) 将中国沪深两地证券市场按地区(不含港澳台)划分,并从复杂网络的角度对证券市场的空间性质进行研究,从中得出一些关于地区指数的结论; 4) 从地区金融网络的拓扑分析中可以看出,中国地区金融网络服从幂律分布; 该网络具有动态的稳定性; 一些经济欠发达地区处于网络中心位置,在分析中国沪深证券市场时不应该被忽略.

在计算动态指标时使用了静态阈值,由于金融市场存在波动率长程关联,下一步将考察动态阈值对指标的影响^[48]. 此外,导致经济欠发达地区在地区复杂网络中重要的原因是什么,是因为这些地区股票家数过少,还是市场本身还有没被发掘的现象? 这也是值得进一步讨论的工作. 将本文提出的方法推广到其他金融领域如外汇市场,在引入量化系统后应用于实际投资以及金融危机的预测等也是值得研究的方向.

参考文献

- [1] Mantegna R N, Stanley H E 1995 *Nature* **376** 46
- [2] Tang Z P, Chen W H, Ran M 2017 *Acta Phys. Sin.* **66** 120203 (in Chinese) [唐振鹏, 陈尾虹, 冉梦 2017 物理学报 **66** 120203]
- [3] Huang J P 2015 *Phys. Rep.* **564** 1
- [4] Chen T T, Zheng B, Li Y, Jiang X F 2017 *Front. Phys.* **12** 128905
- [5] Bodie Z, Kane A, Marcus A J 2012 *Essentials of Investments* 9ED (New York: McGraw-Hill Education) pp217-222, 235-242
- [6] Fama E F 1970 *J. Finance* **25** 383
- [7] Haldane A G, May R M 2011 *Nature* **469** 351
- [8] Han H, Wu L Y, Song N N 2014 *Acta Phys. Sin.* **63** 138901 (in Chinese) [韩华, 吴翎燕, 宋宁宁 2014 物理学报 **63** 138901]
- [9] Mantegna R N 1999 *Eur. Phys. J. B* **11** 193
- [10] Huang W Q, Zhuang X T, Yao S 2009 *Physica A* **388** 2956
- [11] Namaki A, Shirazi A H, Raei R, Jafari G R 2011 *Physica A* **390** 3835
- [12] Wiliński M, Sienkiewicz A, Gubiec T, Kutner R, Struzik Z R 2013 *Physica A* **392** 5963
- [13] Fiedor P 2015 *Acta Phys. Pol. A* **127** A33
- [14] Wang G J, Xie C, Stanley H E 2018 *Comput. Econ.* **51** 607
- [15] Fiedor P, Holda A 2016 *J. Risk Finance* **17** 93
- [16] Jang W, Lee J, Chang W 2011 *Physica A* **390** 707
- [17] Sousa A M Y R, Takayasu H, Takayasu M 2014 *Proceedings of the International Conference on Social Modeling and Simulation, plus Econophysics Colloquium 2014 Kobe, Japan, Nov. 4-6, 2014* p3
- [18] Fan H 2014 *Acta Phys. Sin.* **63** 038902 (in Chinese) [范宏 2014 物理学报 **63** 038902]
- [19] De Masi G, Fujiwara Y, Gallegati M, Greenwald B, Stiglitz J E 2011 *Evolut. Inst. Econ. Rev.* **7** 209
- [20] Gao X Y, An H Z, Liu H H, Ding Y H 2011 *Acta Phys. Sin.* **60** 068902 (in Chinese) [高湘昀, 安海忠, 刘红红, 丁颖辉 2011 物理学报 **60** 068902]
- [21] Zhong W, An H, Fang W, Gao X, Dong D 2016 *Appl. Energy* **165** 868
- [22] Meng H, Xie W J, Jiang Z Q, Podobnik B, Zhou W X, Stanley H E 2014 *Sci. Rep.* **4** 3655
- [23] Meng H, Xie W J, Zhou W X 2015 *Int. J. Mod. Phys. B* **29** 1550181
- [24] Wang G J, Xie C 2015 *Physica A* **424** 176
- [25] Lee J, Youn J, Chang W 2012 *Physica A* **391** 1354
- [26] Tumminello M, Di Matteo T, Aste T, Mantegna R N 2007 *Eur. Phys. J. B* **55** 209
- [27] Münnix M C, Schäfer R, Guhr T 2010 *Physica A* **389** 4828
- [28] Yang C, Shen Y, Xia B 2012 *Mod. Phys. Lett. B* **27** 1350022
- [29] Nobia A, Maenga S E, Haa G G, Lee J W 2014 *Physica A* **407** 135
- [30] Fiedor P 2015 *Acta Phys. Pol. A* **127** 863
- [31] Sandoval Junior L, Franca I D P 2012 *Physica A* **391** 187
- [32] Qiu L, Jia T M, Yang H J 2016 *Acta Phys. Sin.* **65** 198901 (in Chinese) [邱路, 贾天明, 杨会杰 2016 物理学报 **65** 198901]
- [33] Fiedor P 2014 *Phys. Rev. E: Stat. Nonlinear Soft Matter Phys.* **89** 052801
- [34] Shannon C E 1948 *AT. T. Tech. J.* **27** 379
- [35] You T, Fiedor P, Holda A 2015 *J. Risk Financial Manag.* **8** 266

- [36] Fiedor P 2014 *Proceedings of the 2014 IEEE Conference on Computational Intelligence for Financial Engineering & Economics (CIFER)* London, United Kingdom, Mar. 27–28, 2014 p247
- [37] Vergara J R, Estévez P A 2014 *Neural Comput. Appl.* **24** 175
- [38] Coletti P 2016 *Physica A* **463** 246
- [39] Brida J G, Gómez D M, Risso W A 2009 *Expert Syst. Appl.* **36** 7721
- [40] Shenzhen Fortune Trend Technology Co, Ltd <http://www.tdx.com.cn/> [2017-5-11] (in Chinese) [深圳市财富趋势科技股份有限公司 <http://www.tdx.com.cn/> [2017-5-11]]
- [41] Brida J G, Risso W A 2010 *Expert Syst. Appl.* **37** 3846
- [42] Nooy W D, Mrvar A, Batagelj V 2011 *Exploratory Social Network Analysis with Pajek* 2ED (New York: Cambridge University Press) pp344–348
- [43] Blondel V D, Guillaume J L, Lambiotte R, Lefebvre E 2008 *J. Stat. Mech.* **2008** P10008
- [44] Heiberger R H 2014 *Physica A* **393** 376
- [45] Clauset A, Shalizi C, Newman M 2009 *SIAM Rev.* **51** 661
- [46] Xu R, Wong W K, Chen G, Huang S 2017 *Sci. Rep.* **7** 41379
- [47] Snijders T A B, van de Bunt G G, Steglich C E G 2010 *Soc. Networks* **32** 44
- [48] Qiu T, Zheng B, Chen G 2010 *New J. Phys.* **12** 043057

Financial complex network model based on textual mutual information*

Sun Yan-Feng¹⁾ Wang Chao-Yong^{2)†}

1) (College of Computer Science and Technology, Jilin University, Changchun 130012, China)

2) (School of Information Engineering, Jilin Engineering Normal University, Changchun 130021, China)

(Received 21 November 2017; revised manuscript received 22 March 2018)

Abstract

Complex networks are widely used in many problems of the financial field. It can be used to find the topological structure properties of the financial markets and to embody the interdependence between different financial entities. The correlation is important to create the complex networks of the financial markets. A novel approach to incorporating textual mutual information into financial complex networks as a measure of the correlation coefficient is developed in the paper. We will symbolize the multivariate financial time series firstly, and then calculate correlation coefficient with textual mutual information. Finally, we will convert it into a distance. To test the proposed method, four complex network models will be built with different correlation coefficients (Pearson's and textual mutual information's) and different network simplification methods (the threshold and minimum spanning tree). In addition, for the threshold networks, a quantile method is proposed to estimate the threshold automatically. The correlation coefficients are divided into 6 equal parts. And the midpoint of the 4th interval will be taken as the threshold according to our experience, which can make the MI methods and Pearson methods have the closest number of edges to compare the two methods. The data come from the closing prices of Chinese regional indexes including both Shanghai and Shenzhen stock market. The data range from January 4, 2006 to December 30, 2016, including 2673 trading days. In view of node correlation, the numerical results show that there are about 20% of the nonlinear relationships of the Chinese regional financial complex networks. In view of the network topology, four topological indicators for the regional financial complex network models will be calculated in the paper. For average weighted degree, the novel method can make the reserved nodes closely compared with Pearson's correlation coefficient. For network betweenness centralization, it can improve the betweenness importance of reserved nodes effectively. From the perspective of modularity, the novel method can detect better community structures. Finally, in dynamic network topology features, the data of regional indexes will be equally divided yearly for constructing complex network separately. The simplification method used in the section is the threshold method. The numerical results show that the proposed methods can successfully capture the two-abnormal fluctuation in the sample interval with the dynamics of the small-world and the network degree centralization. In addition, we find that the proposed regional financial network models follow the power-law distribution and are dynamically stable. Some developing regions are more important than the developed ones in the regional financial networks.

Keywords: econophysics, textual mutual information, minimal spanning trees, threshold networks

PACS: 89.65.Gh, 89.70.Cf, 89.75.Fb

DOI: [10.7498/aps.67.20172490](https://doi.org/10.7498/aps.67.20172490)

* Project supported by the Fund Program for the Scientific Activities of Selected Returned Overseas Professionals in Jilin Province, China (Grant No. 201523).

† Corresponding author. E-mail: cywang@jleu.edu.cn