

基于大数据视角探究疫情对 A 股市场波动率的影响

雷 蕾¹ 吴天昊² 李 丽³

1. 成都师范学院 数学学院, 中国·四川 成都 610041;
2. 中信银行股份有限公司 成都高新支行运营部, 中国·四川 成都 610095;
3. 北京第二外国语学院成都附属学校 科研部, 中国·四川 成都 610041

【摘要】A股市场在疫情的冲击下,呈现出异常波动,政府部门就此制定了干预政策。本文通过实证分析,运用中断时间序列分析(ITSA)探究疫情对A股市场波动率的影响,并以“武汉封城”为例,量化分析重大政策性干预对该影响的对冲效应。在此基础上,本文基于大数据视角,收集经济政策不确定性指数,建立TVP-VAR模型探索性分析疫情对股市波动率的影响机制和传导路径。结果表明:深市对疫情冲击的耐受能力弱于上市,重大政策性干预的瞬时效应和持续效应更强,即在疫情防控取得成效后,我国二级市场存在“深强于沪”的现象。此外,疫情背景下,经济政策不确定性指数对波动率具有时变性的正向冲击,疫情舆情指数对波动率具有负向冲击。

【关键词】疫情; 中断时间序列分析; TVP-VAR模型; 政策干预; 疫情舆情指数

Exploring the Impact of COVID-19 on China's A Stock Market Volatility Based on Big-Data Perspective

Lei Lei, Wu Tianhao, Li Li

1. College of Mathematics, Chengdu Normal University, Sichuan China, Chengdu 610041
2. Operation Department, Chengdu High-tech Sub-branch, China CITIC Bank Co.Ltd., Sichuan China, Chengdu 610095
3. Research Institute, Chengdu School Affiliated to Beijing International Studies University, Sichuan China, Chengdu 610041

[Abstract] Under the impact of COVID-19, China's stock market has shown unusual fluctuations. we first use ITSA model to explore the impact of the epidemic on A-share volatility, then take "Wuhan-closure" as an example to analyze the hedging effect of government policy interventions on the impact. On this basis, from the perspective of big data, this paper collects the EPU index, constructs the epidemic public opinion index based on microblog text data, then establishes TVP-VAR model to explore the impact mechanism and transmission path of the epidemic on stock market volatility. The results show that: the tolerance of Shenzhen stock market to the impact of the epidemic is weaker than that of Shanghai stock market, but the instantaneous effect and sustained effect of policy intervention on "Wuhan-closure" are stronger. In addition, during the epidemic, the EPU index has a positive impact on volatility, and the public opinion index has a negative impact on volatility. All these results indicate that, COVID-19, as an external shock, needs strong intervention from the government to avoid possible systemic financial risks.

[Keywords] COVID-19; ITSA model; TVP-VAR model; intervention policy; public opinion index

2020年初爆发的新冠肺炎疫情(COVID-19)对我国社会经济运行体系造成了巨大冲击。在疫情的冲击下,国内A股市场同样呈现出明显的异常波动与下行趋势。国内外一些关于疫情如何影响股票市场的最新研究指出,疫情通过引发各种经济活动不确定性影响实体经济运行机制,如经济政策不确定性,商业预期不确定性等,进而冲击股票市场^[1-2]。除上述的疫情影响传导渠道外,疫情本身的快速传播以及网络舆情的蔓延给公众及投资者带来的恐慌情绪,也在一定程度上造成了股票市场的异常波动^[3]。对此,政府部门实施的重大干预政策也许能有效对冲疫情带来的影响,加速我国金融市场的运行重回正轨^[4-5]。

综上,本文将探究疫情爆发我国股票市场波动率冲击的机制和路径,并分析政策性因素、经济政策不确定性因素、疫情网络舆情对股市波动率的影响,以期对当未来可能出现的类似事件的影响分析提供借鉴和实证参考。具体来说,本文首先

对疫情冲击下的A股市场波动率进行了刻画,并基于中断时间序列分析(ITSA)量化了“武汉封城”政策性干预对该影响的对冲效应。其次,本文通过大数据技术合理量化疫情引发的不确定性,收集经济政策不确定性指数,使用深度学习模型(BERT)基于微博文本数据量化疫情网络舆情指数,并建立时变参数向量自回归(TVP-VAR)模型来探究不同时期疫情对股市波动率的动态影响路径和潜在传导机制。

1 文献综述

疫情引起的各种不确定性因素影响了实体经济的正常运行,经济政策不确定性指数,股市波动率指数以及商业预期调查中的不确定性指数可作为相关代理变量,用于量化疫情对经济运行带来的影响^[1]。由于投资者对疫情发展趋势和造成影响的认识往往来源于新闻媒介,所以基于新闻报刊量化的经济政策不确定性指数(EPU)能够用于解释疫情对股票市场造成的波动

[2]。除宏观经济层面的影响因素外, 疫情的快速传播还极大地冲击了网络舆情, 带来恐慌情绪, 这也在一定程度上导致了股指的异动[3]。对此, 政府部门实施的重大干预政策, 如封城管控政策, 央行货币政策, 政府补贴政策等很可能会有效对冲疫情带来的影响, 使我国金融市场重获生机, 经济发展重回正轨[4-5]。

关于如何量化疫情背景下的网络舆情, 近些年来, 逐渐流行并趋于成熟的自然语言处理技术(NLP)为该研究领域提供了技术支持。对于如何把网民情绪与股票市场联系起来, Bollen 等认为, 可以收集得到海量 Twitter 文本数据, 并使用自然语言处理技术(NLP)将网民情绪的变化表征为情绪时序数据, 这些包含了 Twitter 用户情绪的时序数据能够在一定程度上有效预测股市的波动和走势[6]。Vagenas 等则基于 Facebook 的用户情绪指数进行研究, 发现该指数与股市收益率之间存在较为明显的正影响关系, 并且负面情绪占比, 交易量的增加均与波动率有关[7]。李勇敢等则通过收集大量微博文本数据, 结合吉布斯抽样法, 建立了主题词提取模型, 并利用该模型有效实现了中文微博情感倾向的分类[8]。刘维奇等则基于投资人评论进行情感分析, 分析了股票波动率对个人投资者和机构投资者情绪变化的敏感度, 结果表明股票波动对机构投资者情绪的变化更为剧烈和灵敏[9]。

国外一些学者已经对疫情如何影响股票市场做出了一些开创性的探索, 而关于疫情对我国股市的影响路径或传导机制方面的研究目前还不太丰富。因此, 为丰富国内相关领域的实证研究, 在借鉴此类创新型研究理论和方法的基础上, 分析疫情对我国股市波动的影响是有意义的。

2 理论模型与数据

2.1 理论模型

2.1.1 波动率的测度

由于已实现波动率(Realized Volatility)具有无模型、无偏性和较好的稳健性等优点, 可作为股市真实波动率的一致估计量[10]。本文使用已实现波动率作为股市波动率的测度方法, 首先定义 $p(t)$ 是金融资产的对数价格过程, 投资于该金融资产 Δ 时段上的对数收益率如式(1)所示: $r(t, \Delta) = p(t+\Delta) - p(t)$

进而, 可定义时刻 t 的已实现波动率如式(2)所示:

$$\sigma_{t,\Delta}^2 = \sum_{j=1}^{1/\Delta} r_{t-1+j\Delta,\Delta}^2 \quad (2)$$

上式中, Δ 为时间间隔, $1/\Delta$ 为抽样频率, 当 Δ 无限趋于 0 时, 意味着连续取样, 这时, 已实现波动率将收敛于积分波动率。

在计算已实现波动率的过程中, 由于市场微观结构通常包含不可观测噪声, 随着抽样频率升高, 这种噪声所占的比重同样会升高, 导致计算结果不精确。因此, 抽样过程通常是在精度与噪声之间进行权衡取舍进行的, 相对而言, 5 分钟间隔的高频数据在保证抽样频率较高的前提下, 还不易受到微观结构中不可观测噪声带来的影响[11]。为此, 本文考虑选择 5 分钟

频率的股市高频交易数据进行实证研究, 即取 $\Delta = 5\text{min}$, 每日的抽样频率为 $1/\Delta = 48$ 。

2.1.2 中断时间序列分析

为探究某事件对某一时序变量是否有显著影响, 主要采用事件研究法(Event Study)和中断时间序列分析法(ITSa)进行研究[12]。

当仅有一个研究对象时, 即没有控制组时, 可进行单组干预分析。此时, 标准 ITSa 回归模型如式如下所示:

$$Y_t = \beta_0 + \beta_1 T_t + \beta_2 X_t + \beta_3 X_t T_t + \varepsilon_t \quad (3)$$

其中 Y_t 是结果变量 Y 在每个等时间间隔时间点 t 上的观测值; T_t 描述研究开始以来的时间; X_t 是一个描述干预情况的虚拟变量, 在干预发生之前为 0, 其他时间为 1; $X_t T_t$ 是交互项。截距 β_0 代表结果变量的初始水平; β_1 代表结果变量在干预发生前的斜率或轨迹; β_2 代表于反事实结果相比较, 结果变量在干预发生后的瞬时变化量; β_3 代表在干预发生前后段回归线斜率间的差异。通常而言, 将关注的重点放在 β_2 和 β_3 的显著性上, 因为它们分别描述干预的瞬时影响和持续影响。定义随机误差项 ε_t 服从正态分布 $(0, \sigma^2)$ 。

进行中断时间序列分析时, 必不可少地要考虑到自相关性带来的影响, 在实践中常见的解决方法是采用 OLS 回归。使用 OLS 回归估计的系数, 产生 Newey-West 标准误用于处理自相关性以及可能的异方差, 并对残差进行检验, 以此来保证模型的正确性。

2.1.3 深度双向预训练模型

BERT, 即 Bidirectional Encoder Representations from Transformers, 中文译为用于语言理解的深度双向预训练模型, 该模型主要包含无监督预训练(Pre-training)和下游微调(Fine-Tuning)两个部分, 该模型已被证实自然语言处理的诸多应用领域取得了瞩目的效果[13]。

由于谷歌官方开源了 BERT 关于世界主流语言的预训练模型, 研究者省去了耗费大量计算资源的预训练过程, 可根据不同任务需求, 选择合适的语言和模型进行下游微调, 便可达到目的。在本研究中, 选用 BERT-Base, Chinese 预训练模型, 该模型共有 12 层, 包含 1.1 亿个参数, 下游任务接口选用 Text-CNN 网络进行文本情感分类。

2.1.4 TVP-VAR 模型

通常而言, 常使用向量自回归模型(VAR)对多维时间序列变量进行建模, 进而分析各变量之间的互动关系或影响机制。但 VAR 模型存在一个颇具局限性的假设, 即系数和扰动项的方差固定不变, 在这种假设下, 模型难以捕捉经济背景和政策环境随时间推移所发生的变化。时变参数向量自回归(TVP-VAR)模型有效弥补了 VAR 模型的不足, 通过允许系数和反应冲击的协方差矩阵随时间推移不断发生变化, 模型的滞后结构和变量间的动态时变关系均能够得到较好的刻画。与 VAR 模型采用 OLS 进行参数估计不同, TVP-VAR 模型通常采用 MCMC 方法

确保参数估计的有效性^[14]。

2.2 数据说明

基于Wind数据库收集得到A股市场中沪深300指数2020年1月20日至2020年3月31日的期间的5分钟日内高频价格数据,用于计算日度已实现波动率,记作变量RV。同样收集到陆尚勤等编制的中国经济政策不确定性指数日度数据^[16],记作变量EPU,该指数近些年被应用于诸多金融热点问题相关研究^[17-18]。为合理量化疫情网络舆情指数,本文通过大数据手段,通过指定一系列“疫情”相关关键词,爬取到研究时间段内101万份微博评论数据,其中10万条评论数据作为已有标签的训练集,1代表积极情感,0代表中性情感,-1为消极情感,90万条评论数据作为预测集,另取1万条评论数据作为验证集,使用BERT进行训练。最终,BERT对于该三分类任务的准确度达到86.79%,其F1得分系数为0.8388,取得了不错的效果。为测度疫情网络舆情指数,本文采用每日积极评论数与消极评论数的比值来进行构造,该指数记为变量SENTIMENT,如式(4)所示,其值越大,表明疫情网络舆情呈向好扩散趋势。

$$SENTIMENT_t = \frac{\sum I_{\alpha}(A)}{\sum I_{\beta}(A)} \quad (4)$$

上式中,A代表时间t日内微博评论的情感分类结果,

$$I_{\alpha} = \begin{cases} 1, A=1 \\ 0, A \neq 1 \end{cases} \text{ 代表积极评论判别的示性函数,}$$

$$I_{\beta} = \begin{cases} 1, A=-1 \\ 0, A \neq -1 \end{cases} \text{ 代表消极评论判别的示性函数。}$$

经处理后,最终得到46个有效样本数据ⁱ。

3 实证分析

3.1 疫情对股票波动,政策不确定性以及网络舆情的影响

对2.2中涉及各变量进行最值归一化处理后,其时序趋势如图1所示。由图1可看出,自疫情于2020年1月20日被官方证实存在“人传人”现象后,EPU呈现出显著的波动,而RV则先呈现出明显的上升趋势,之后随着防疫政策的实施和疫情防控局面的好转,RV大体上呈现出下降的趋势,直到2020年3月中旬,RV再次大幅波动上升,除疫情的影响因素外,可能还与美国股市在此期间接连发生的四次熔断有较大联动效应。此外,SENTIMENT在疫情爆发初期呈现出一个明显的负面扩散现象,之后由于防疫政策的实施和疫情防控局面的好转,逐渐呈现出向好发展的趋势。到了2020年3月初由于疫情在全球内大面积扩散,导致SENTIMENT呈现出异常的波动,直到2020年3月下旬,由于国内疫情防控已经取得初步成效,SENTIMENT再次呈现出向好的上升趋势。

3.2 重大政策干预对疫情影响的对冲效应

本文认为疫情将通过多种途径对A股市场带来影响,进而引发股指异动,在疫情爆发后,政府部门实施的重大干预政策,如封城政策,央行货币政策,政府补贴政策以及封闭管

理政策等很可能会有效对冲该影响。本文以“武汉封城”政策性干预为例,量化分析重大政府干预手段对该影响的对冲效应。为突出干预效果,选择相关事件前后20个交易日作为事件窗口期。以上证指数代表沪市,以深圳成指代表深市分别计算已实现波动率,作为结果变量。针对沪深两个具有不同代表性的市场,本文基于单一变量RV构建单组干预分析的中断时间序列模型,采用一期滞后的Newey-West稳健回归进行估计,结果如下表1所示。




图1 各变量时序图

表1 回归结果

	变量	系数	Newey-West 标准误	t	P值	95%置信区间	
上证市场	T _t	0.6006	0.0698	8.6001	0.0000	0.4525	0.7486
	X _t	-1.6892	0.5172	3.2703	0.0051	-2.7858	-0.5926
	T _t X _t	-0.6796	0.0634	-10.724	0.0002	-0.8140	-0.5452
	常数项	0.1625	0.1179	1.3800	0.1872	-0.0873	0.4125
	变量	系数	Newey-West 标准误	t	P值	95%置信区间	
深圳市场	T _t	0.7830	0.0907	8.6304	0.0000	0.5907	0.9752
	X _t	-1.8710	0.7272	-2.5702	0.0201	-3.4126	-0.3293
	T _t X _t	-0.9450	0.0852	-11.090	0.0000	-1.1256	-0.7643
	常数项	0.5790	0.1882	3.0811	0.0072	-0.1800	0.9780

此外,上证市场及深证市场残差序列Q检验P值均此外,为确保建立的中断时间序列模型能够正确地描述自相关结构,对残差序列进行了Q检验,结果表明对于上证市场及深证市场残差均不存在自相关性。

由表1中β1系数结果可知,在“武汉封城”政策干预生效前,疫情将造成上证市场的波动率以0.6006的趋势升高,深证市场的波动率以0.7830的趋势升高。结果充分说明了疫情对A股市场带来了巨大冲击,导致市场波动率上升。此外,深圳市场波动率的上升趋势比上证市场更高,说明深圳市场对疫情冲击的承受能力相对较差。

由表1中β2系数结果可知,“武汉封城”政策干预生效后,上证市场的波动率瞬时下降1.6892,而深圳市场的波动率瞬时下降1.8710。这说明“武汉封城”政策干预对疫情带来的影响具有瞬时对冲效应,并且深圳市场的瞬时变化较上证市场而言更加剧烈,说明其受政策性因素影响的瞬时反应程度更强。

由表1中β3系数结果可知,系数,代表“武汉封城”政策干预发生后,上证市场的波动率将以0.6796的趋势持续下降,深

圳市场的波动率将以 0.9450 的趋势持续下降。这说明“武汉封城”政策干预对疫情带来的影响具有持续对冲效应，并且深圳市场的持续变化趋势较上证市场而言更加剧烈，说明其受政策性因素影响的持续反应程度也更强。

3.3 疫情对A股市场波动率的影响机制

前文的分析已经证实疫情的确会造成A股市场波动率升高，并以“武汉封城”政策干预为例，检验了政府部门施行的重大政策性干预手段对该影响的对冲效应，主要回答了“有没有影响”这一问题。而后文将探索性地分析疫情对A股市场波动率的潜在影响机制和传导路径，试图回答“如何影响”这一问题。

使用沪深300指数的已实现波动率作为A股市场波动率的代表，记为变量RV，经济政策不确定性指数记为变量EPU，疫情网络舆情指数记为SENTIMENT，并基于以上三个变量，建立TVP-VAR模型。

3.3.1 平稳性检验

在建立TVP-VAR模型前，应对以上三个时序变量进行平稳性检验，ADF单位根检验的结果如表2所示①。

表2 平稳性检验

变量	检验形式	ADF统计量	P值	结论
EPU	(0, 0, 2)	-1.6928	0.0853*	不平稳
Δ EPU	(C, 0, 1)	-9.2938	0.0000***	平稳
SENTIMENT	(C, 0, 1)	-2.0624	0.2603	不平稳
Δ SENTIMENT	(C, 0, 0)	-13.3368	0.0000***	平稳
RV	(C, 0, 1)	-2.6535	0.0903*	不平稳
Δ RV	(C, 0, 0)	-12.7980	0.0000***	平稳

注：1. ADF单位根检验的形式为(C, T, K)，其中，C, T, K分别代表常数项，时间趋势项和根据SIC准则选择的滞后阶数；2. Δ 表示一阶差分运算；3. P值右上角的*、**、***分别表示在10%、5%、1%的显著性水平上拒绝存在单位根的零假设。

由结果可知，在0.05的显著性水平下，三个序列变量均非平稳，但它们的一阶差分序列均是平稳的，即为一阶单整序列，可考虑进行Johansen协整检验，如下表4所示。

表3 Johansen 协整检验

原假设	特征值	迹统计量	5%临界值	P值
$r=0$	0.5357	40.9187	24.2759	0.0002
$r\leq 1$	0.1400	7.1533	12.3209	0.3101
$r\leq 2$	0.0116	0.5139	4.1299	0.5362

注：r表示协整方程个数。

由表3可知，变量间至少存在一个长期协整关系，根据协整理论，选用的以上三个变量可以直接用于构建TVP-VAR模型。

3.3.2 模型估计

由于理论界对TVP-VAR模型滞后阶数选择标准的暂无定论且存在一些争议，在本研究中，暂且参照VAR模型的定阶方法来确定TVP-VAR模型的滞后阶数。包含以上三变量的TVP-VAR模型滞后阶数检验的结果如下表4所示。

上述结果显示，绝大多数检验准则都认为滞后2期最优，于是，将TVP-VAR模型的滞后阶数定为2阶。

在进行参数估计时，采用MCMC方法进行了20000次模拟，得到了可用于模型参数估计的有效独立样本。

表4 模型定阶

滞后阶数	LogL	LR	FPE	AIC	SC	HQ
0	-229.4996	NA	41.3976	12.2368	12.3661	12.2828
1	-212.2145	30.9312	26.8289	11.8008	12.3179*	11.9848
2	-198.7257	22.0080*	21.4053*	11.5645*	12.4695	11.8865*
3	-190.7927	11.6907	23.2215	11.6207	12.9135	12.0807

注：1.*：表示由对应准则选取的最佳滞后阶数；2.LR：为修正的似然比检验统计量（每项检验5%置信水平）；3.FPE：为最终预测误差；4.AIC：为最佳赤池准则；5.SC：为Schwarz信息准则；6.HQ：为Hannan-Quinn信息准则。

表5 参数估计结果

参数	均值	标准误	95%置信区间	Geweke统计量	无效因子
sb1	-0.0226	0.0018	-0.0194 - 0.0264	0.595	1.85
sb2	-0.0225	0.0018	-0.0194 - 0.0264	0.202	2.36
sa1	-0.1621	0.0608	-0.0649 - 0.2939	0.020	90.54
sa2	-0.0751	0.0207	-0.0470 - 0.1252	0.032	16.25
sh1	-0.0768	0.0223	-0.0476 - 0.1314	0.577	17.88
sh2	-0.0812	0.0373	-0.0483 - 0.1436	0.707	51.16

表5展示了参数估计的结果，参数的后验均值均在95%的置信区间内，且Geweke统计量的CD收敛诊断值都小于1.96，即在0.05的显著性水平下，不能拒绝收敛于后验分布的原假设。此外，所有参数的无效因子均在100以下，这说明使用MCMC方法进行20000次抽样得到的样本是收敛的，利用该抽样所得的样本对TVP-VAR模型进行参数估计是有效且充分的。在通过模型的检验和诊断后，将进行各变量之间的脉冲响应分析。

3.3.3 脉冲响应分析

将中国股票市场的波动率作为被解释变量，图2和图3分别给出了RV对EPU和SENTIMENT的脉冲响应，考虑选取冲击影响时间约束为1天和5天，分别代表超短线股票市场约束和短线股票市场的约束。




图2 RV对EPU的脉冲响应图




图3 RV对SENTIMENT的脉冲响应图

如上图所示,在超短线市场约束下,冲击曲线随时间的推移而不断发生明显的变化,而在短线市场约束下,冲击的时变性相对较弱。具体而言,从图2中可以看出:对于不同时间的市场约束而言,股市波动率对中国经济政策不确定性冲击的脉冲响应函数曲线始终为正,这表明了在疫情背景下,中国经济政策不确定性对我国股市的波动率具有正向冲击。从趋势上来看,股市波动率对中国经济政策不确定性冲击的超短线脉冲响应函数曲线在整体上呈现出一个明显下降趋势并逐渐衰减为0,而这种趋势在短线股票市场中表现得并不明显。从图3中可以看出:对于超短线股票市场而言,股市波动率对疫情网络舆情的脉冲响应函数曲线始终为负,并且时变性较弱。在短线市场中,股市波动率对疫情网络舆情冲击的短期脉冲响应函数曲线先为负,并随时间的推移逐渐递减为0。

3.3.4 稳健性分析

由于波动率的测度方式有多种,本文在实证分析中采用已实现波动率作为波动率的测量方式,而在本小节中,将采用基于隐含波动率计算的中国波动率指数,即iVIX指数进行稳健性检验。具体而言,使用iVIX指数代替变量RV构建TVP-VAR模型,中国波指(iVIX)对中国经济政策不确定性指数(EPU)和疫情舆情指数(SENTIMENT)的脉冲相应如图4和图5所示。




图4 iVIX对EPU的脉冲响应图




图5 SENTIMENT对EPU的脉冲响应图

由图4和图5的结果可知,替换了波动率的测度方式为隐含波动率后,波动率对相关变量的脉冲响应方向与变化趋势均在

大体上与前文实证分析中得出的结果是一致的,这说明结论是稳健的。

4 结论与建议

(1) 疫情将增大中国经济政策不确定性,进而影响中国股市的波动率。在疫情爆发期间,从不同的时间约束来看,股市波动率对中国经济政策不确定性冲击的脉冲响应函数曲线始终为正,但随着疫情防控措施的完备和复工复产的有序推进,这种影响逐渐减弱并趋于零。

(2) 疫情冲击网络舆情,舆情向坏扩散程度越高,将显著导致中国股市的波动率上升。在超短期时间约束的情况下,相较于经济政策不确定性而言,舆情的冲击具有较低的时变性,但具有更强的时效性。而从短期时间约束来看,在疫情防控取得初步成效后,舆情向好扩散同样会刺激市场,市场行情有所回暖,导致股指呈现上行波动。

(3) 政府部门出台的重大政策性干预手段,政策性干预有效对冲了疫情给我国股票市场波动率带来的影响。干预生效前后,我国二级市场波动率呈现出扭转式的变化。并且在沪深两市的对比分析中,本文发现,深圳市场对疫情冲击的耐受程度更低,但对于政策性干预的瞬时和持续响应程度更高。在疫情防控取得一定成效后,我国二级市场存在深强于沪的现象。

根据实证研究得到的主要结论,本文提出两点建议:第一、疫情作为一次外部冲击导致我国金融市场发生动荡,需要政府部门迅速反应并制定相关干预政策,降低经济政策不确定性,以避免可能导致的系统性金融风险。第二、网络舆情不仅扩散极快,其对金融市场造成的冲击也是迅速而灵敏的,政府部门必须及时有效地监管网络舆情,要加强官方媒体对舆论走向的正确引导,每一名网络参与者也应加强网民责任意识。在以上两种途径的有效配合下,疫情作为一次外部冲击,不会对我国金融市场造成系统性风险,这种影响也将在疫情防控机制趋于完善、复工复产有效推进下逐渐消失。

注释:

①研究时段内,由于股票市场在春节假期和周末停盘,变量RV有46个观测值,而EPU和SENTIMENT两个变量均有72个观测值。为保证各变量的数据频数相同,将EPU和SENTIMENT两个变量在节假日的数据与下一个交易日的数据计算平均值作为各自在节假日后第一个交易日的数据。于是,实证模型中的每个变量均包含了46个有效的观测值。

参考文献:

- [1] Baker S R, Bloom N, Davis S J, et al. The unprecipitated stock market impact of COVID-19[R]. National Bureau of Economic Research, 2020.
- [2] Baker S R, Bloom N, Davis S J, et al. Covid-induced economic uncertainty[R]. National Bureau of Economic Research, 2020.

[3] Medford R J, Saleh S N, Sumarsono A, et al. An "infodemic": leveraging high-volume twitter data to un-

derstand public sentiment for the COVID-19 outbreak[R]. medRxiv, 2020.

[4] 朱军, 张淑翠, 李建强. 突发疫情的经济影响与财政干预政策评估[J]. 经济与管理评论, 2020, 36(3): 21-32.

[5] 胡滨, 范云朋, 郑联盛. “新冠”疫情、经济冲击与政府干预[J]. 数量经济技术经济研究, 2020, 37(9): 42-61.

[6] Bollen J, Mao H, Zeng X. Twitter mood predicts the stock market. Journal of Computational Science, 2011, 2(1): 1-8.

[7] Siganos A, Vagenas-Nanos E, Verwijmeren P. Facebook's daily sentiment and international stock markets [J]. Journal of Economic Behavior & Organization, 2014, 107: 730-743.

[8] 李勇敢, 周学广, 孙艳, 张焕国. 中文微博情感分析研究与实现[J]. 软件学报, 2017, 28(12): 3183-3205.

[9] 刘维奇, 刘新新. 个人和机构投资者情绪与股票收益——基于上证A股市场研究[J]. 管理科学学报, 2014, 17(3): 70-87.

[10] Andersen T, Bollerslev T, Diebold F, Labys P. Modeling and forecasting realized volatility[J]. Econometrica, 2003, 71(2): 579-625.

[11] 黄后川, 陈浪南. 中国股票市场波动率的高频估计与特性分析[J]. 经济研究, 2003(02): 75-82+94.

[12] 于石成, 王琦琦, 毛凡, 李洋, 石佳欣, 张曼晖, 龙晓娟, 金

承刚. 中断时间序列设计及其分析方法[J]. 中华预防医学杂志, 2019(8): 858-864.

[13] Devlin J, Chang M W, Lee K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding[R]. arXiv: 1810.04805, 2018.

[14] Nakajima J. Time-varying parameter VAR model with stochastic volatility: An overview of methodology and empirical applications[R]. Institute for Monetary and Economic Studies, Bank of Japan, 2011.

[15] Huang Y, Paul Luk. Measuring economic policy uncertainty in China[J]. China Economic Review, 2020, 59: 101367.

[16] 王伟强. 经济政策不确定性对产出增长的非对称效应[J]. 统计与信息论坛, 2021, 36(3): 49-59.

[17] 李佳霖, 董嘉昌, 张倩肖. 经济政策不确定性、融资约束与企业投资[J]. 统计与信息论坛, 2019, 34(10): 73-83.

作者简介:

雷蕾(1988-), 女, 四川成都人, 助教, 硕士, 研究方向: 金融统计方向。

吴天昊(1996-), 男, 四川成都人, 硕士, 研究方向: 统计学大数据方向。

李丽(1979-), 女, 四川成都人, 讲师, 硕士, 研究方向: 应用统计方向。