

中国金融压力实时监测研究¹

——基于混频大数据动态因子模型的分析

党印² 苗子清³ 张涛⁴

摘 要 防范化解系统性金融风险是维护金融安全 and 经济安全的内在要求,关键要对风险进行准确度量 and 实时监测。本文运用混频动态因子模型,构建基于传统金融统计数据和网络搜索大数据的日度频率中国金融压力指数(FSI),度量并监测中国的系统性金融风险。研究表明:所构建的FSI能度量并监测中国系统性金融风险,指数的阶段性变化特征和区制状态识别结果与系统性金融风险的现实演进情况高度吻合;经济主体的预期不确定性和风险感知是金融压力的主要来源,并且金融压力有较强的持续性;引入大数据指标对FSI模型的估计具有明显改善作用,并能提高FSI对产出、通胀等宏观经济变量的预测效果;“高压”区制下的FSI对月同比CPI增速的预测效果较好,“低压”区制下的FSI对GDP增速的预测效果较好。监管部门未来需继续优化金融风险监测预警体系,提升监测能力,合理引导市场预期。

关键词 金融压力;实时监测;大数据;混频动态因子模型

0 引言

2008年全球金融危机中,一些大型金融机构的财务危机引发一系列金融机构及各类金融市场陷入危机,由此产生的系统性金融风险引起各国政府高度重视。中国政府在多项政策文件中一再强调,要“守住不发生系统性金融风险的底线”。防范化解系统性金融风险事关金融安全 and 经济安全,国内外学界围绕相关问题展开了多方面研究,其中的关键问题是度量和监测系统性金融风险,

¹ 本文是研究阐释党的十九届五中全会精神国家社科基金重大项目“中央银行的逻辑与现代中央银行制度的建设”(项目编号:21ZDA045)的阶段性成果。作者感谢匿名审稿专家的宝贵意见,文责自负。

² 党印(通讯作者),中国劳动关系学院副教授,E-mail:dangyin1999@163.com。

³ 苗子清,东方证券股份有限公司博士后工作站研究人员,E-mail:miaoziqing@ucass.edu.cn。

⁴ 张涛,中国社会科学院大学经济学院教授,E-mail:zhangtao@cass.org.cn。

为防范化解风险提供必要的依据和参考。

系统性金融风险一般指极端事件引起金融体系一连串持续损失的可能性(Kaufman, 1996), 根据这种损失可能性的宏观影响和微观机制, 现有度量系统性金融风险的方式大致分为两类: 从宏观影响上看, 损失可能性将导致金融体系基本功能丧失, 相关研究从反映金融体系整体功能稳定性的角度, 提出了金融稳定指数(IMF, 2002)、金融状况指数(Goodhart and Hofmann, 2001; Gauthier et al., 2004)、金融脆弱性指数(Kibritcioglu, 2002)和金融稳定状况指数(Vanden End, 2006)等; 从微观机制上看, 损失可能性也会对经济主体的心理和情绪造成影响, 从而对经济主体的金融交易、信用配置等行为形成压力, 因此相关研究(Illing and Liu, 2006; Hakkio and Keeton, 2009; Van Roye, 2011等)从反映经济主体的心理和情绪的角度, 用金融压力指数(Financial Stress Index, FSI)来刻画系统性金融风险。然而, 从系统性金融风险的本质来看, 正是因为经济主体行为和心理状态的变化以及经济主体间持续的交互式反馈作用, 导致风险在横向和纵向维度上具有传染和扩散效应, 使系统性金融风险具有内生性特征(马勇, 2011), 同时宏观经济和金融体系之间也具有动态关联性, 多重因素影响下导致金融体系有内在的不稳定性(张勇等, 2017)。从宏观经济学的微观基础来看, 通过金融压力反映和度量系统性金融风险, 能从微观主体层面刻画系统性金融风险的缘起和演进。金融压力的概念被提出以后, 世界各国监管当局广泛关注, 学界也进行了深入研究。

本文以金融压力指数度量系统性金融风险水平, 运用混频动态因子模型, 综合传统金融数据和非传统大数据, 构建2008年1月—2021年6月月度频率的中国金融压力指数(FSI), 以实时监测中国的系统性金融风险。研究表明: 所构建的金融压力指数(FSI)能度量并监测中国的系统性金融风险, 指数的阶段性变化特征和区制状态识别结果与系统性金融风险的现实演进情况高度吻合, 准确识别了2008年以来历次的极端金融事件和经济波动; 微观经济主体的风险感知和预期不确定性是金融压力的主要来源, 相关表征指标与金融压力指数显著正相关, 同时中国金融压力具有较强的持续性; 大数据指标的引入对FSI模型的估计起到明显改善作用, 并能提升FSI对产出、通胀等宏观经济变量的预测效果。

本文的边际贡献主要有三点: 一是结合金融压力的内涵, 采用网络搜索大数据编制市场危机情绪指数(Crisis Sentiment Index, CSI), 从新的视角衡量经济主体的风险感知情况, 并加入到金融压力指数的基础指标体系中, 拓展了监测系统性金融风险的数据范围, 进一步改进了系统性金融风险的监测方法。二是运用经过拓展的动态因子模型, 有效利用各类高频和低频数据, 在最大程度保留数据原始信息的基础上构建中国金融压力指数, 将系统性金融风险的监测频

率从季度、月度扩展到日度,实现更精准地实时监测。三是分析大数据对金融压力指数模型估计和预测的影响,为学界研究金融压力指数与宏观经济变量之间关系提供了新的经验证据。

余文结构安排如下:第1部分回顾现有文献并简要评述;第2部分构建金融压力指数(FSI)的监测模型,并建立指标体系;第3部分是中国金融压力指数(FSI)的实时监测;第4部分是结论与政策含义。

1 文献回顾与评述

金融压力(financial stress)主要指金融机构和金融市场中的不确定性或不断变化的损失预期给经济主体带来的压力,最早由 Illing and Liu(2006)提出。之后,Hakkio and Keeton(2009)、Van Roye(2011)、苗子清等(2021)基于经济主体情绪心理过程对金融压力做了进一步的阐释,认为金融压力首先是金融市场的情况对投资者、决策者等经济主体的情绪和心理造成的压力,主要表现为经济主体对金融资产基本价值和整个经济前景预期的不确定性以及对预期损失的风险感知增加,进而影响投资交易、借贷等金融行为,最终引起系统性金融风险的集聚和爆发。由此,我们认为金融压力本质上是经济主体的情绪心理和行为在外生影响下发生变化,并反映到金融市场中,市场发展情况进一步影响经济主体的情绪和心理,循环演变。

金融压力可以用基于序数的连续变量来表示,其极值代表经济主体的风险感知和预期不确定性较强,投资行为和交易行为为非理性,金融体系的资源配置功能受损,产生系统性金融风险的可能性较大;其正常值代表经济主体的风险感知和预期不确定性较弱,投资交易等金融行为较为理性,金融体系的资源配置功能保持正常,产生系统性金融风险的可能性较小。认识和降低金融压力的前提是准确度量金融压力,目前国内外文献大多以构建金融压力指数(FSI)的方法度量和监测金融压力。

国外研究方面,Illing and Liu(2006)选取银行部门指标、外汇市场汇率基本价值偏离、债券市场风险债券与无风险债券息差、股票市场股权风险溢价等不同金融子市场的11个金融月度指标,运用因子分析法、规模权重法和方差权重法等三种方法构建加拿大金融压力指数(FSI)。Hakkio and Keeton(2009)选取TED利差、2年期掉期利差、非流动和流动10年期国债利差、AAA级债券与10年期国债利差、股票市场波动率等11个金融月度指标,运用主成分分析法合成美国堪萨斯城的金融压力指数(KCFSI)。Balakrishnan et al.(2009)将银行部门值、股票市场收益率、股票市场波动率、主权债务利差、EMPI(外汇市场压力指数)等月度指标作为组成变量,采用等方差权重法,得到了适用于新兴经济体的

金融压力指数(EM-FSI)。Kliesen and Smith(2010)选取联邦基金利率、10年期与3个月国债利差、TED利差、芝加哥期权交易所市场波动指数等,运用主成分分析法构建美国圣路易斯金融压力指数(STLFSI)。Van Roye(2011)运用动态因子模型,将货币市场利差、公司债券利差、DAX指数波动率、实际有效汇率波动率等原始压力月度数据合成为金融市场压力指数,分别构建德国和欧元区的金融风险度量指标。Holló et al.(2012)运用与五个金融子市场^①相关的指标,包括3个月欧元银行间同业拆借利率波动率、10年期利率互换利差、非金融部门股票市场指数波动率、A级金融公司与非金融公司债券利差、欧元兑美元汇率波动率等,选取每周数据构建反映各市场压力程度的子指标,并以这些子指标间具有时变性的相关系数矩阵为权重,合成综合性金融压力指标(CISS)。总体而言,国外的这些金融压力指数指标丰富、方法多样,对认知金融压力有一定的借鉴意义。

国内研究方面,中国学者借鉴国外文献提出的金融压力概念和研究方法,结合中国实际构建了识别国内系统性金融风险的中国金融压力指数。第一类文献是选取关键指标,为指标设定固定权重。赖娟和吕江林(2010)采用等权重法,选择股市波动率、银行风险利差、期限利差和EMPI等4个月度金融指标,得出显示系统性风险状态的中国金融压力指数。许涤龙和陈双莲(2015)采用客观赋权法,选取存贷比、股票市盈率、实际有效汇率指数、住宅销售价格指数等各金融子市场月度指标,构建中国金融压力指数(FSI),与赖娟和吕江林(2010)的区别在于细分指标不同,权重不同。第二类文献扩大了指标范围,为指标设定动态变化的权重。张勇等(2017)选取3个月银行间同业拆借利率与定期存款利率之差、1年期与10年期银行间固定利率国债收益率之差、上证综合指数GARCH波动率、人民币名义有效汇率GARCH波动率、国房景气指数GARCH波动率等指标,分别反映银行、债券、股票、外汇和房地产市场,基于月度数据和时变权重法构建中国金融压力指数,指标范围进一步扩大,并引入新的权重方法。沿承这一方法,清华大学国家金融研究院金融与发展研究中心课题组(2019)选取3个月FR007利率互换、非金融部门股票波动率、金融部门市净率、美元兑人民币汇率波动率等涵盖债券市场、金融部门、股票市场和外汇市场的13个周度子指标,并运用动态赋权法合成了中国系统性金融压力指数(CISS)。之后,丁慧等(2020)选取SHIBOR波动率、期限利差、股票指数波动率、人民币兑美元汇率波动率等基础月度指标分别构建货币、债券、股票、外汇等金融各子市场压力指数后,采用时变权重法,构建了中国金融市场压力指数(CFMSI)。第三类文献设定多样化的代表性指标,采用多种指标合成方法。马勇和黄科(2019)结合CDF转换、等权重、主成分分析等方法,使用隔夜SHIBOR利率波动

^① 货币市场、债券市场、资本市场、金融中介和外汇市场。

率、股票市场 CMAX、银行业 CMAX/银行业市净率、人民币兑美元汇率波动率等货币市场、债券市场、股票市场、外汇市场和银行部门 10 个代表性周度指标,采用累积分布函数转换、等权重、主成分分析等方法构建了中国金融压力指数(FSI)。郑金麟等(2019)选择银行业风险利差、股票波动率、汇率波动率、芝加哥期货交易所波动率等金融子市场月度数据,采用等方差权重法,构建了中国金融压力指数。与国外文献相比,国内的研究在指标范围和构建方法方面还有待进一步拓展和优化。

纵观现有文献,目前构建金融压力指数所采用的方法主要是赋权法、主成分分析法和动态因子模型法等,所选择的基础指标主要是反映经济主体预期不确定性的资产价格波动率、反映经济主体风险感知的资产利差^①等传统金融指标,通过这些方法和指标虽然可以得到金融压力指数的结果,但是存在需要改进的地方:第一,从金融风险监测的角度看,时效性有所不足。现有文献主要基于季度、月度或周度基础指标,所构建的金融压力指数频率较低,尚未实现对金融风险的逐日实时监测。第二,指数合成方法存在一定缺陷。赋权法中权重的选择没有基于明确的经济学理论基础,没有反映出“系统性”金融压力与局部金融压力的区别,也没有抓住金融压力所衡量的系统性金融风险的本质。主成分分析法虽然能够提取所选定变量的共同因子,反映出系统性金融风险所引起各金融子市场的共同变化趋势,但无法对不同频率的数据进行处理。第三,基础指标选择上仍需进一步拓展。现有文献构建指数所选取的数据主要是传统金融统计数据,非传统大数据尚未得到有效利用。事实上,许多前沿文献(Kostopoulos et al., 2020; Nyman et al., 2021; 肖争艳和任梦瑶, 2021 等)已经表明,从行为金融的视角,网络搜索、文本分析等大数据也可以用来构建经济主体风险感知指标,并有助于提高金融风险监测识别的精准度。鉴于现有文献的瓶颈和不足,本文将综合运用传统金融统计数据和网络搜索大数据,引入经济主体风险感知指标,拓展现有的动态因子模型,构建基于日度的中国金融压力指数(FSI)并进行实时监测,以期进一步提升系统性金融风险识别的精准性和及时性,为中国金融监管部门防范化解系统性金融风险提供参考。

2 监测模型及指标体系

2.1 基于混频动态因子模型提取 FSI 的基本原理

为了实时监测金融压力,更及时地跟踪金融市场的压力变化状况,本文将

^① 经济主体对预期损失的风险感知提高,在金融行为上会表现为追逐高质量和高流动性资产,将导致资产利差上升;经济主体对经济前景和资产基本价值预期的不确定性提高,将导致资产价格的波动率上升(Hakkio and Keeton, 2009; Bloom, 2009)。

蕴含丰富信息的高频数据纳入模型,在高频数据观测频率上直接关联低频信息,保证不同数据频率上的关键指标均可有效利用。我们以日频率作为时间标度,基于日度数据构建模型,低频(例如月度)指标若无相应的观测值则记为缺失值,并采用 Kalman 滤波方法以保证模型的估计不受到个别缺失值的影响。令 x_t 表示时刻 t 的金融压力指数,且 x_t 是不可观测的变量,假设其服从 AR(p) 过程动态变化,即

$$x_t = \rho_1 x_{t-1} + \rho_2 x_{t-2} + \cdots + \rho_p x_{t-p} + e_t \quad (1)$$

其中, e_t 是方差为 1 的白噪声。令 y_t^i 表示 t 时刻第 i 个可观测变量,线性依赖于 x_t ,也依赖于外生变量和 y_t^i 的滞后项:

$$y_t^i = c_i + \beta_i x_t + \delta_{i1} w_t^1 + \cdots + \delta_{ik} w_t^k + \gamma_{i1} y_{t-D_i}^i + \cdots + \gamma_{in} y_{t-nD_i}^i + u_t^i \quad (2)$$

其中, w_t 是外生变量, u_t^i 为同期连续不相关的信息。 y_t^i 滞后项的滞后期是 D_i 的整数倍, D_i 是每个观察期的天数,与观测变量 y_t^i 的频率有关(比如若 y_t^i 的频率为周度则 $D_i=7$)。实际上,通常 D_i 是时变的,例如一个月可能有 28 天、29 天、30 天或 31 天。为了简化表示,本文假设式(2)中的 D_i 是固定的。在接下来的实证检验中,采用的是时变的 D_i 。

同时,假设金融压力具有高、低两个区制,并由区制 s_t 控制。当 $s_t=1$ 时,金融压力处于高水平的区制;当 $s_t=0$ 时,金融压力处于低水平的区制。本文运用马尔科夫区制转移模型构建金融压力动态因子 x_t ,以及其区制 s_t 和 s_{t-1} 的联合分布函数 $F(x_t, s_t, s_{t-1} | x_{t-1})$ 和对数似然函数 $\ln L$:

$$F(x_t, s_t, s_{t-1} | x_{t-1}) = F(x_t | s_t, s_{t-1}, x_{t-1}) \cdot Pr(s_t, s_{t-1} | x_{t-1}) \quad (3)$$

$$\ln L = \sum_{t=1} \ln \left[\sum_{s_t=1} \sum_{s_{t-1}=1} F(x_t | s_t, s_{t-1}, x_{t-1}) \right] \cdot Pr(s_t, s_{t-1} | x_{t-1}) \quad (4)$$

进一步求解对数似然函数,概率值 $Pr(s_t | x_t)$ 可以通过式(5)和式(6)递归计算。

$$Pr(s_t | x_t) = \sum_{s_{t-1}=1} Pr(s_t, s_{t-1} | x_t) \quad (5)$$

$$Pr(s_t, s_{t-1} | x_t) = \frac{F(x_t | s_t, s_{t-1}, x_{t-1}) Pr(s_t, s_{t-1} | x_{t-1})}{\sum_{s_t=1} \sum_{s_{t-1}=1} F(x_t | s_t, s_{t-1}, x_{t-1}) Pr(s_t, s_{t-1} | x_{t-1})} \quad (6)$$

2.2 模型的状态空间表示

在对模型进行估计时,先将上述模型改写为状态空间的形式:

量测方程:

$$y_t = C + Z_t \alpha_t + \Gamma_t w_t + \varepsilon_t \quad (7)$$

转移方程:

$$\alpha_{t+1} = \mu_{s_t} + T \alpha_t + R \eta_t \quad (8)$$

$$\varepsilon_t \sim (0, H_t), \quad \eta_t \sim (0, Q), \quad t = 1, \dots, \bar{T} \quad (9)$$

其中, y_t 为 $N \cdot 1$ 的观测变量向量, α_t 为 $m \cdot 1$ 的状态变量向量, C, μ_{s_t} 是截距项, w_t 是包含 k 个趋势项和 $N \cdot n$ 的因变量滞后项的前定变量向量, ε_t, η_t 是包含 u_t^i 和 e_t 的量测方程和转移方程随机扰动向量。 $\bar{T}$ 是时间序列观测的最后一期。 T, R 和 Q 是恒定不变的矩阵, 但是由于 t 中的 D_t 是时变的, 因此 Z_t, Γ_t 和 H_t 也是时变的。

y_t^i 表示以日度为频率的第 i 个变量。大多数变量虽然每天都在变化, 实际上并不是每天都能观察到。因此, 令 $\tilde{y}_t^i$ 表示在较低频率下观察到的相同变量, y_t^i 是存量变量还是流量变量将决定 $\tilde{y}_t^i$ 和 y_t^i 之间的关系。

如果 y_t^i 是存量变量, 由于其是在某一特定时点的结存数量, 所以在任何时刻 t, y_t^i 可以被观测到, 在这种情况下则 $\tilde{y}_t^i = y_t^i$; y_t^i 不可以被观测到, 在这种情况下则 $\tilde{y}_t^i = \text{NA}$, 其中 NA 表示缺失数据。

如果 y_t^i 是流量变量, 由于其是在某一特定时期的发生数量, 所以在任何时刻 t , 非日度频率下观测到的数值等于观测期内相应日度数值的加总, 即

$$\tilde{y}_t^i = \begin{cases} \sum_{j=0}^{D_t-1} y_{t-j}^i & y_t^i \text{ 被观测到} \\ \text{NA} & \text{其他} \end{cases} \quad (10)$$

2.3 动态因子模型设定

参考 Aruoba et al. (2009)、陈磊等 (2019) 和王艺枫等 (2019) 的模型设定, 按照 AIC 和 SBIC 信息准则, 将动态因子模型的滞后阶数定为 1 阶。同时, 由于高阶滞后形式会导致参数的表达式更加复杂、估计更加困难, 因此本文采用精简的模型形式, 具体形式见式 (11) 至式 (13), 并采用最大似然法对模型进行估计。

$$\begin{bmatrix} \tilde{y}_t^1 \\ \tilde{y}_t^2 \\ \tilde{y}_t^3 \\ \tilde{y}_t^4 \\ \tilde{y}_t^5 \\ \tilde{y}_t^6 \end{bmatrix} = \begin{bmatrix} \beta_1 & \beta_2 & \beta_3 & \beta_4 & \beta_5 & \beta_6 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} x_t \\ u_t^1 \\ u_t^2 \\ u_t^3 \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ \gamma_4 & 0 & 0 \\ 0 & \gamma_5 & 0 \\ 0 & 0 & \gamma_6 \end{bmatrix} \begin{bmatrix} \tilde{y}_{t-M}^4 \\ \tilde{y}_{t-M}^5 \\ \tilde{y}_{t-M}^6 \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ 0 \\ \tilde{y}_t^4 \\ \tilde{y}_t^5 \\ \tilde{y}_t^6 \end{bmatrix} \quad (11)$$

$$\begin{bmatrix} x_t \\ u_t^1 \\ u_t^2 \\ u_t^3 \end{bmatrix} = \begin{bmatrix} \rho & 0 & 0 & 0 \\ 0 & \gamma_1 & 0 & 0 \\ 0 & 0 & \gamma_2 & 0 \\ 0 & 0 & 0 & \gamma_3 \end{bmatrix} \begin{bmatrix} x_{t-1} \\ u_{t-1}^1 \\ u_{t-1}^2 \\ u_{t-1}^3 \end{bmatrix} + \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} e_t \\ \zeta_t^1 \\ \zeta_t^2 \\ \zeta_t^3 \end{bmatrix} \quad (12)$$

其中,

$$\begin{bmatrix} \varepsilon_t \\ \eta_t \end{bmatrix} \sim N\left(\begin{bmatrix} 0_{6 \times 1} \\ 0_{4 \times 1} \end{bmatrix}, \begin{bmatrix} H_t & 0 \\ 0 & Q \end{bmatrix}\right), \quad H_t = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \sigma_{4t}^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & \sigma_{5t}^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & \sigma_{6t}^2 \end{bmatrix},$$

$$Q = \begin{cases} \begin{bmatrix} 1-\rho^2 & 0 & 0 & 0 \\ 0 & \sigma_1^2 & 0 & 0 \\ 0 & 0 & \sigma_2^2 & 0 \\ 0 & 0 & 0 & \sigma_3^2 \end{bmatrix} & \rho \neq 1 \\ \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & \sigma_1^2 & 0 & 0 \\ 0 & 0 & \sigma_2^2 & 0 \\ 0 & 0 & 0 & \sigma_3^2 \end{bmatrix} & \rho = 1 \end{cases} \quad (13)$$

2.4 指标体系

2.4.1 传统金融数据指标体系

本文构建金融压力指数的传统金融指标包括银行体系的利率,及债券、股票、外汇和房地产市场的资产价格波动率。具体而言,银行部门选取银行间同业隔夜(O/N)拆借利率与同业1年期拆借利率的利差,债券市场选取3个月与10年期国债到期收益率的期限利差,股票市场选取股价波动率(对日度收益率取绝对值),外汇市场选取实际有效汇率波动率(对月度收益率取绝对值),房地产市场选取房地产销售额波动率(对月度环比增长率取绝对值)。2008年全球金融危机爆发,系统性金融风险成为各国关注的热点,本文以此为分析起点,同时兼顾数据的可得性,样本区间为2008年1月1日—2021年6月30日。以上传统金融指标的基本信息详见表1。

表 1 传统金融指标的基本信息

指标	具体变量	符号	频度	样本区间	数据来源
利率	隔夜 (O/N) 与 1 年期 SHIBOR 利差	Yield	日度存量	2008 年 1 月 1 日—2021 年 6 月 30 日	Wind 数据库
国债收益率	3 个月国债与 10 年期国债到期收益率利差	Bond	日度存量	2008 年 1 月 1 日—2021 年 6 月 30 日	Wind 数据库
股价	股价波动率	Stock	日度存量	2008 年 1 月 1 日—2021 年 6 月 30 日	Wind 数据库
汇率	实际有效汇率波动率	NEER	月度存量	2008 年 1 月—2021 年 6 月	Wind 数据库
房地产销售额	房地产销售额波动率	Housesale	月度存量	2008 年 1 月—2021 年 6 月	国家统计局官网

2.4.2 网络搜索大数据指标体系

如今,随着“大数据”时代来临,海量而庞杂的新型大数据源带来传统类型数据所没有的新信息。特别在经济金融领域,网络搜索大数据可用于度量各类经济主体的情绪,直接客观地揭示经济主体的风险感知情况。借鉴 Da et al. (2015)、Irresberger et al. (2017)、Brochado (2020) 和 Kostopoulos et al. (2020) 的做法,本文运用网络搜索大数据来编制市场危机情绪指数 (CSI),并尝试纳入到金融压力的估计模型中,数据来源为百度指数中多个关键词的搜索趋势。

在运用网络搜索大数据进行经济金融分析时,关键词的选择至关重要,直接关系到分析结果的准确性和科学性。本文选取关键词及构建市场危机情绪指数的具体步骤为:

第一,综合运用主观选词法、模型选词法和参考文献法^①构建反映金融风险和市场担忧情绪的初始词库。第二,运用网页爬虫技术,分别抓取初始词库中每个关键词在百度指数网页上的每日搜索频率,整理为月度数据,并按照不同维度对搜索频率数据进行加总。第三,采用因子分析法估计各个得分系数的矩阵,将各因子的方差百分比作为对应权重,与各因子数值相乘并求和后得到市场危机情绪指数。由于每个关键词的词频相差较大,在因子分析前,将关键词词频进行标准化处理,标准化公式为:标准化词频数=(月词频-样本期内词频的最小值)/(样本期内词频的最大值-样本期内词频的最小值)。网络搜索大数据指标的基本信息详见表 2。

^① 主观选词法指根据研究者的经验进行主观判断确定关键词的方法;模型选词法包括百度搜索引擎的长尾关键词拓展法、需求图谱拓展法和网页链接搜索拓展法;参考文献法指参考借鉴经典文献确定关键词的方法。

表 2 网络搜索大数据指标的基本信息

一级指标	二级指标	符号	包含关键词	样本区间	数据来源
网络搜索 大数据指标	宏观经济类	MacroR	经济下滑 $M_1 \sim$ 债务危机 M_{17}	2008 年 1 月 1 日— 2021 年 6 月 30 日	百度指数网页
	外部冲击类	ExternalR	次贷危机 $E_1 \sim$ 新冠疫情 E_{20}	2008 年 1 月 1 日— 2021 年 6 月 30 日	百度指数网页
	银行机构类	BankR	钱荒 $B_1 \sim$ 银行破产 B_{13}	2008 年 1 月 1 日— 2021 年 6 月 30 日	百度指数网页
	非银行机构类	UbankR	股灾 $U_1 \sim$ 房价暴跌 U_{18}	2008 年 1 月 1 日— 2021 年 6 月 30 日	百度指数网页

注:宏观经济类指标包括经济下滑、经济衰退、三期叠加、经济新常态、新常态、经济危机、通货膨胀、滞胀、通货紧缩、失业率、出口贸易、中国出口贸易、外贸出口、债务危机、地方债务、地方债、地方融资平台等 17 个关键词;外部冲击类指标包括金融危机、2008 年金融危机、金融海啸、金融风暴、美国金融危机、次贷危机、美国次贷危机、雷曼兄弟、欧债危机、欧洲债务危机、希腊债务、中美贸易战、中美贸易摩擦、美国加征关税、英国脱欧、英国脱欧公投、新冠疫情、COVID-19、新冠病毒、新冠肺炎疫情等 20 个关键词。银行机构类指标包括钱荒、SHIBOR、银行间同业拆借利率、不良贷款、不良资产、资本充足率、拨备覆盖率、银行挤兑、影子银行、银行理财、刚性兑付、银行倒闭、银行破产等 13 个关键词;非银行机构类指标包括股灾、股市崩盘、股市下跌、股市大跌、千股跌停、熔断、熊市、A 股走势、非法集资、高利贷、地下钱庄、P2P 跑路、P2P 爆雷、恒大爆雷、恒大违约、房地产泡沫、房价下跌、房价暴跌等 18 个关键词。

图 1 显示了市场危机情绪指数的合成结果。在一般情况下,市场危机情绪指数较为平稳,大致维持在 0~0.1 的区间水平。但在诸如 2008 年国际金融危机、2010—2012 年欧债危机、2013 年“钱荒”事件、2015 年“股灾”、2018—2019 年中美贸易战、2020 年新冠肺炎疫情等极端风险事件期间,市场危机情绪指数发生了明显波动,与均值的偏离均超过了 1.5 个标准差。特别是 2008 年金融危机期间,市场危机情绪指数的极值超过了 0.5,2013 年“钱荒”事件和 2015 年“股灾”期间,市场危机情绪指数的极值均超过了 0.3。下文进行金融压力测度时,




图 1 市场危机情绪指数趋势图

本文将合成的市场危机情绪指数波动率(月度环比变化率)也代入估计模型。

3 中国金融压力指数(FSI)的实时监测

3.1 模型估计结果

根据上述基准模型和数据指标,本文使用 RATS 软件编写算法程序,以估计模型参数。表 3 给出了模型的参数估计结果。首先,绝大部分参数在统计学意义上十分显著,能够反映混频模型的设定具有合理性。因子载荷 β_1 、 β_2 、 β_3 、 β_4 、 β_5 在 1% 的显著性水平上均显著为正,说明隔夜(O/N)与 1 年期 SHIBOR 利差、3 个月国债与 10 年期国债到期收益率利差、股价波动率、实际有效汇率波动率和房地产销售额波动率与金融压力正相关且对金融压力具有显著影响。在 1% 的显著性水平上, β_6 也十分显著且为正值,说明由网络搜索大数据指标构建的市场危机情绪指数与金融压力正相关,并且市场危机情绪指数对金融压力指标有显著影响。其次,金融压力指数的自回归系数为 0.9981,且在统计学意义上具有显著性,与尚玉皇和郑挺国(2018)的估计结果接近,说明中国金融压力的持续性较强。最后,删除网络搜索大数据信息后,采用其余传统指标变量进行混频 FSI 模型估计,模型参数的标准差均有所扩大,说明本文的混频大数据金融压力指数模型估计结果优于基于传统金融指标的度量模型,引入大数据信息可明显改善估计效果。

表 3 混频大数据金融压力指数模型参数估计结果

参数	估计值	标准差	参数	估计值	标准差
β_1	0.1633 ***	(0.0394)	γ_4	0.2540 ***	(0.0642)
β_2	0.1008 ***	(0.0214)	γ_5	0.0700	(0.0654)
β_3	0.0117 ***	(0.0026)	γ_6	0.6451 ***	(0.0037)
β_4	0.0078 ***	(0.0020)	σ_1	0.0208 ***	(0.0004)
β_5	0.0047 ***	(0.0010)	σ_2	0.0112 ***	(0.0002)
β_6	0.0430 ***	(0.0114)	σ_3	-0.0101 ***	(0.0001)
ρ	0.9981 ***	(0.0008)	σ_4	-0.0078 ***	(0.0004)
γ_1	0.9783 ***	(0.0035)	σ_5	-0.0063 ***	(0.0005)
γ_2	0.9993 ***	(0.0004)	σ_6	-0.0505 ***	(0.0026)
γ_3	-0.0243	(0.0230)			
LogL	27956.6893				

注： β_1 、 β_2 、 β_3 、 β_4 、 β_5 、 β_6 分别表示隔夜(O/N)与 1 年期 SHIBOR 利差、3 个月国债与 10 年期国债到期收益率利差、股价波动率、实际有效汇率波动率、房地产销售额波动率、市场危机情绪指数对应的因子载荷。***、**、* 分别表示 1%、5%、10% 的显著性水平。括号内数值表示参数估计结果的标准差。LogL 表示对数似然函数值。

3.2 实时 FSI 的阶段性变化特征

图2显示了基于混频大数据动态因子模型的FSI测度结果。由于使用了日度数据进行建模,所以该指数波动较为频繁,能更加及时地跟踪金融压力的变化情况。FSI系列指数在0水平轴以上波动,当指数大幅上升,表明整个金融市场的金融压力增大,发生系统性金融风险的可能性上升,金融形势趋于恶化;当指数下降,表明整个金融市场的金融压力减小,发生系统性金融风险的可能性下降,金融形势趋于好转。自2008年以来,由于相继发生美国次贷危机、欧债危机、2013年“钱荒”事件、2015年“股灾”、中美贸易战、新冠肺炎疫情等对中国金融市场影响较大的极端经济金融事件,FSI呈现比较明显的阶段性变化特征,苗子清(2020)、苗子清和张卓群(2020)曾专门分析,进一步的具体分析如下:




图2 2008年1月1日—2021年6月30日的中国FSI趋势图

第一阶段为2008年1月至2009年12月。2007年中国银行体系流动性过剩引起资产价格泡沫,美国次贷危机引发全球金融危机,在这两方面的影响下,中国系统性金融风险和金融压力在2008年明显增加,金融压力指数在高位区间波动。2008年10月,中国政府出台“四万亿”经济刺激计划以应对全球金融危机带来的冲击,综合运用多种宏观审慎政策调控经济,经济平稳增长,系统性金融风险保持在合理范围。从2009年开始,系统性金融风险逐渐降低,金融压力指数不断下降,逐步回归到合理区间。

第二阶段为2010年1月至2012年12月。2010—2011年,希腊主权评级被全球三大评级公司下调等级,欧洲债务危机爆发,整个欧盟陷入主权债务危机的泥潭,中国出口贸易受到明显冲击,企业和居民对外投资风险加大,人民币汇率波动增加了金融市场的不确定性。与此同时,随着“四万亿”经济刺激计划逐步实施,中国出现流动性过剩、产能过剩和预期通胀率上升等问题,金融压力再次增加,FSI波动加剧并呈上升趋势。面对国内外形势,中国政府推出一系

政货币政策,加大政策的针对性和灵活性,合理引导货币供求和资金流向。综合调控后,2012年金融市场平均运行,利率、汇率和物价水平保持平稳,各地经济稳定增长,金融压力水平开始下降。

第三阶段为2013年1月至2015年12月。2013年6月银行间市场资金面紧张,市场流动性短缺,银行同业拆借利率和国债回购利率高企,发生“钱荒”事件,金融市场面临的流动性压力大幅增加,金融压力指数迅速上升。2014年11月,中国央行下调金融机构存贷款基准利率和存款准备金率,简并基准利率期限档次,鼓励银行向企业提供资金支持。由于实体经济不景气,一些企业将资金投向股票市场,出现“脱实向虚”现象,股市泡沫随之积累。2015年6月至8月,沪深股指下跌近一半,大量个股股价暴跌,发生“股灾”,股市泡沫破灭,中国的金融压力再次凸显,金融压力指数上升到高位区间。

第四阶段为2016年1月至2017年12月。中国政府加强宏观审慎监管,深入推进金融体系改革,明确提出“牢牢守住不发生系统性金融风险的底线”,并将其作为各级金融监管部门的基本工作要求,中国人民银行、中国银保监会和中国证监会分别出台多项“强监督、强监管”措施,地方金融监管部门全面监督实施,系统性金融风险得到有效控制,金融压力逐步降低,金融压力指数保持低位。

第五阶段为2018年1月至2019年12月。2018年3月美国挑起“中美贸易争端”,中国的制造业出口和高技术产品进口受到冲击,中美贸易摩擦增加。与此同时,中国供给侧结构性矛盾尚存,新的经济增长点尚不明显,各个金融市场的不确定性增加,股市暴跌,人民币兑美元汇率多次突破7.0,金融压力进入累积上升期,FSI开始逐渐上升。之后,中美两国就经贸问题开展了多轮对话和磋商,经过双方的共同努力,于2019年12月13日就中美第一阶段经贸协议文本达成一致,贸易摩擦有所缓和,金融压力指数也呈下隆态势。

第六阶段为2020年1月至2021年6月。2020年1月新冠肺炎疫情暴发,多个行业受到冲击,一些行业陷入停滞,金融压力加大,金融压力指数上升。在疫情防控 and 救助措施的推动下,一些行业回归正常运行状态,经济逐渐复苏,金融系统压力得到缓和,金融压力指数整体呈现下降趋势。2020年下半年后,由于受到疫情反复、“德尔塔”变异病毒传播、金融体系不良资产规模上升等因素影响,FSI又有所反弹。2021年,多省疫情得到控制,进入常态化疫情防控阶段,经济金融呈转好趋势,金融压力指数开始平稳下降。

3.3 实时FSI的区制状态识别

基于混频动态因子模型得到FSI,本文进一步构建马尔科夫区制转移模型,识别FSI的不同区制,并以此判断中国金融压力的状态和拐点。

设定 FSI 这一状态变量存在“低压力水平”“高压力水平”两种区制。当低压力的平滑概率高于 0.5 时为低压力水平区域,当高压力的平滑概率高于 0.5 时为高压力水平区域。本文采用 MS-AR 模型进行分析,按照 AIC 和 BIC 准则将模型的最佳滞后阶数定为 0 阶,运用基于 EM 算法的 OxMetrics 6.0 软件可以估计得出区域平滑概率(见图 3)。




图 3 高压力区制平滑概率图

模型估计得到“高压力水平”区制的稳定概率为 99.10%,平均持续周期为 115 天,持续的时间段分别为 2008/1/1—2009/3/25、2010/12/24—2010/12/29、2013/6/20—2013/6/28、2014/12/8—2015/2/3、2015/4/12—2015/10/22、2015/12/22—2016/3/2、2020/3/1—2020/3/14。“低压力水平”区制的稳定概率为 99.85%,平均持续周期为 590 天,持续的时间段分别为 2009/3/26—2010/12/23、2010/12/30—2013/6/19、2013/6/29—2014/12/7、2015/2/4—2015/4/11、2015/10/23—2015/12/21、2016/3/3—2020/2/29、2020/3/15—2021/6/30。以上结果表明,实时 FSI 的区制状态识别结果与中国金融压力演变的实际情况较为一致。

3.4 实时 FSI 的样本外预测效果

大量文献(徐国祥和李波,2017;邓创和赵珂,2018;马勇和黄科,2019 等)表明,金融压力与宏观经济之间具有紧密的关联性,因此 FSI 可以用来预测产出、通胀等宏观经济变量,其预测效果的好坏也是评价 FSI 的检验标准。在实际应用中,考察第 t 期 FSI 的预测能力,需使用基于 $1 \sim t$ 期实时可获取数据估计得到的 FSI,而非根据全样本数据($1 \sim \bar{T}$ 期)估计得到的 FSI。按照这一原则,本文采用递归样本,逐月重新计算了 2017 年 6 月末至 2021 年 5 月末的 48 期实时 FSI 序列,并取在样本区间内每个季度的季末值代入预测模型进行估计,以和在该时期能够获得的其他经济数据信息序列相对应。在对产出、通胀进行预测

时,我们在经典产出方程、价格方程的基础上分别引入 FSI 变量(模型表达式见式(14)、(17))进行回归,其中 Y_t 代表产出水平,用 GDP 增速来表示; Y_{t-1} 表示滞后一期的 GDP 增速; r_{t-1} 、 π_{t-1} 分别代表滞后一期的名义利率和通货膨胀率,用 1 年期银行间同业拆借利率和 CPI 来表示,则 $r_{t-1}-\pi_{t-1}$ 代表滞后一期的实际利率; FSI_{t-i} 代表滞后 i 期的 FSI,从滞后一期开始,直到滞后 $m+1$ 期 FSI 与产出、通胀水平无显著相关关系为止。样本区间从 2008 年 1 季度至 2017 年 2 季度开始,估计出预测模型参数然后进行样本外 1 步预测,得到 2017 年 3 季度的预测值。接着将样本区间的截止日期向后推进 1 个季度,重新估计预测模型参数再进行样本外 1 步预测,重复此过程 16 次,相应得到直至 2021 年 2 季度的 16 期预测值。以经典产出方程(式(15))、价格方程(式(17))作为基准模型,同样进行递归 1 步预测,得到 2017 年 3 季度至 2021 年 2 季度的预测值。为检验大数据指标对 FSI 预测效果的影响,我们也将删除网络搜索大数据信息仅采用传统金融指标变量得到的 FSI_F 代入预测模型,估计模型参数,并计算模型的均方根误差(RMSE)、相对 RMSE 统计量、平均绝对误差(MAE)、平均绝对百分比误差(MAPE),比较模型间的预测效果。同时,为了验证 FSI 预测宏观经济变量的优越性,本文也运用以往研究常用的中国金融条件指数(Financial Condition Index, FCI),建立预测模型(式(15)、(18))以对比预测效果。

产出方程:

$$Y_t = \alpha_1 Y_{t-1} + \beta_1 (r_{t-1} - \pi_{t-1}) + \gamma_1 FSI_{t-i} + \varepsilon_t, \quad i = 0, 1, \dots, n \quad (14)$$

$$Y_t = \alpha_1 Y_{t-1} + \beta_1 (r_{t-1} - \pi_{t-1}) + \gamma_1 FCI_{t-i} + \varepsilon_t, \quad i = 0, 1, \dots, n \quad (15)$$

$$Y_t = \alpha_2 Y_{t-1} + \beta_2 (r_{t-1} - \pi_{t-1}) + \varepsilon_t, \quad i = 0, 1, \dots, n \quad (16)$$

价格方程:

$$\pi_t = \alpha_3 \pi_{t-1} + \beta_3 Y_{t-1} + \gamma_3 FSI_{t-i} + \varepsilon_t, \quad i = 0, 1, \dots, n \quad (17)$$

$$\pi_t = \alpha_3 \pi_{t-1} + \beta_3 Y_{t-1} + \gamma_3 FCI_{t-i} + \varepsilon_t, \quad i = 0, 1, \dots, n \quad (18)$$

$$\pi_t = \alpha_4 \pi_{t-1} + \beta_4 Y_{t-1} + \varepsilon_t, \quad i = 0, 1, \dots, n \quad (19)$$

由表 4 可以看出,包含大数据和传统金融指标信息的实时 FSI、仅包含传统金融指标信息的实时 FSI_F 的预测模型对 GDP 增速、月同比 CPI 的预测结果整体优于基准模型,采用 FCI 的预测模型的预测结果整体上不如基准模型、采用 FSI 的预测模型,说明当前实时 FSI、实时 FSI_F 较以往常用指标 FCI 的预测效果更佳,能够在基准模型的基础上提供更多的产出、价格信息,并较为准确地预测 GDP 增速、月同比 CPI 等宏观经济变量。同时,采用实时 FSI 的预测模型的预测结果好于采用实时 FSI_F 的预测模型,说明大数据指标的加入,在传统金融指标信息的基础上进一步增加了信息含量,提高了实时 FSI 对 GDP 增速、月同比 CPI 等宏观经济变量的预测效果。另外,在所有预测模型中,包含滞后 1 阶实时 FSI 变量的预测模型预测效果是最好的,说明在实际应用中,应最优选

择滞后 1 阶实时 FSI 变量对 GDP 增速、月同比 CPI 进行预测。

表 4 样本外实时预测结果(2017 年 3 季度—2021 年 2 季度)

预测变量	预测模型	选取指标	MAE	MAPE	RMSE	相对 RMSE
Y	式(16)	—	0.01392	0.25795	0.02965	1.00000
	式(14)	FSI(-1)	0.01388	0.18540	0.02816	0.94974
	式(14)	FSI(-2)	0.01443	0.19123	0.02842	0.95852
	式(14)	FSI(-3)	0.01481	0.20671	0.02860	0.96459
	式(14)	FSI_F(-1)	0.01394	0.19397	0.02836	0.95649
	式(14)	FSI_F(-2)	0.01445	0.19802	0.02856	0.96324
	式(14)	FSI_F(-3)	0.01485	0.20820	0.02869	0.96762
	式(15)	FCI(-1)	0.01414	0.26398	0.02984	1.00641
	式(15)	FCI(-2)	0.01593	0.29076	0.03039	1.02496
	式(15)	FCI(-3)	0.01929	0.34273	0.03235	1.09106
π	式(19)	—	0.00650	0.39555	0.00902	1.00000
	式(17)	FSI(-1)	0.00620	0.39551	0.00859	0.95233
	式(17)	FSI(-2)	0.00626	0.39726	0.00862	0.95565
	式(17)	FSI(-3)	0.00649	0.39973	0.00864	0.95787
	式(17)	FSI_F(-1)	0.00633	0.40228	0.00869	0.96341
	式(17)	FSI_F(-2)	0.00647	0.40456	0.00871	0.96563
	式(17)	FSI_F(-3)	0.00649	0.40483	0.00879	0.97450
	式(18)	FCI(-1)	0.00655	0.41761	0.00915	1.01441
	式(18)	FCI(-2)	0.00670	0.47244	0.00947	1.04989
	式(18)	FCI(-3)	0.00692	0.49747	0.00972	1.07761

注:MAE 统计量、MAPE 统计量、RMSE 统计量越小,意味着模型预测精度越高;相对 RMSE 统计量小于 1,说明预测模型优于基准模型。

进一步地,为了考察采用 FSI 的宏观经济变量预测模型的预测精度随时间所发生的变化,本文还使用向前跨度为 15 期的滚动法计算各期的 RMSE。由于各期 RMSE 值的计算需要向前 15 期值和本期值,所得到的 RMSE 值从 2017 年 3 季度月至 2021 年 2 季度,相关结果如图 4 所示。可以看到,2017 年 3 季度至 2019 年 4 季度预测 GDP 的 RMSE 值较小,2020 年 1 季度至 2021 年 2 季度预测 GDP 的 RMSE 值较大,结合 FSI 的区制状态识别结果,说明“低压力水平”区制的 FSI 预测 GDP 的效果较好、“高压力水平”区制的 FSI 预测 GDP 的效果较差;然而,2017 年 3 季度至 2019 年 4 季度预测 CPI 的 RMSE 值较大,2020 年 1 季度至 2021 年 2 季度预测 CPI 的 RMSE 值较小,说明“高压力水平”区制的 FSI 预测 CPI 的效果较好、“低压力水平”区制的 FSI 预测 CPI 的效果较差。可能的原因是当 FSI 处于“低压力水平”时,金融市场处于理性状态,金融压力能影响未来经济增长,不易向物价水平传导;但当 FSI 处于“高压力水平”时,金融市场处

于非理性状态,金融压力影响未来经济的结果较为不确定,但容易导致未来物价水平上涨。




图4 滚动法计算得到预测 GDP 和 CPI 各期的 RMSE 值

3.5 实时 FSI 的稳健性检验

图5显示了2020年7月—2021年6月的实时FSI估计序列,其中FSI_202008、FSI_202010、FSI_202103、FSI_202105对金融压力有所高估,FSI_202012、FSI_202102对金融压力有所低估,FSI_202104、FSI_202106的趋势基本重合。总体上看,随着新数据不断增加,FSI的估计结果虽然会进行一定程度上的修正,但基于实时数据的FSI与基于最终数据的FSI(FSI_202106)的走势基本保持一致,这说明本文所构建的混频大数据动态因子模型具有稳健性。




图5 2020年7月1日—2021年6月30日实时FSI估计序列

4 结论与政策含义

准确度和监测系统性金融风险是防范和化解风险的必要依据。近年来行为金融学的研究表明,经济主体预期不确定性和风险感知变化导致非理性金融行为,是系统性金融风险的内生根源之一,不过在如何度量经济主体的风险感知方面还处于探索阶段,将其应用于衡量金融压力的研究亦刚刚起步。

本文基于网络搜索大数据编制市场危机情绪指数,从行为金融的视角丰富了经济主体风险感知指标。同时,将大数据指标与传统金融统计指标相结合,基于混频动态因子模型构建 2008 年 1 月—2021 年 6 月日度频率的中国金融压力指数(FSI),将该指数的监测频率从现有大多数文献的季度、月度和周度频率扩展到日度频率上,并基于该指数考察金融压力的时变特征和该指数对宏观经济变量的预测效果。研究发现:第一,所构建的 FSI 能度量并监测中国的系统性金融风险,指数的阶段性变化特征和区制状态识别结果与中国系统性金融风险现实演进情况高度吻合。第二,从 FSI 估计模型的参数结果来看,传统金融指标和大数据指标所衡量的经济主体预期不确定性和风险感知与金融压力正相关,金融压力具有较强的持续性,加入大数据信息对 FSI 模型估计具有明显的改善作用。第三,产出、通胀等宏观经济变量样本外预测结果显示,FSI 对宏观经济变量具有良好的预测能力,大数据指标的引入可以提升 FSI 的预测效果。第四,不同区制状态的 FSI 对宏观经济变量的预测效果各异,“低压力水平”区制的 FSI 预测 GDP 的效果较好,“高压力水平”区制的 FSI 预测 CPI 的效果较好。

基于上述研究结论,本文的政策含义有三点:第一,将高频金融压力指数纳入系统性金融风险监测预警体系。金融监管部门将日度频率金融压力指数作为日常监测系统性金融风险的重要工具之一,纳入中国系统性金融风险监测预警体系,并加强对系统性金融风险的实时动态监测,以便及时发现并快速处置各类风险点。第二,运用多种技术和方法,不断提升系统性金融风险识别监测能力。在当前金融业数字化转型速度不断加快的背景下,需大力探索大数据、人工智能等前沿科技技术在金融风险管理中的应用,关注更大范围的非传统金融数据,引入更先进的大数据分析方法,持续提升系统性金融风险的识别和监测能力。第三,加强对市场情绪的测度,合理引导市场预期。系统性金融风险发生与市场情绪心理和风险感知有很大关联,应加强对金融投资者、消费者等市场主体情绪的测度,完善舆情监测体系,合理引导市场预期,防止恐慌和非理性情绪扩散引发系统性金融风险。

参考文献

- 陈磊,王艺枫,孟勇刚. 2019. 基于混频数据的中国服务业景气指数构建与周期波动分析[J]. 财贸研究, 30(2): 17-26.
- Chen L, Wang Y C, Meng Y G. 2019. Construction of China's service sector's coincident index and cycle fluctuation analysis based on mixed-frequency data[J]. *Finance and Trade Research*, 30(2): 17-26. (in Chinese)
- 邓创,赵珂. 2018. 中国的金融压力及其对宏观经济景气的影响动态[J]. 财经研究, 44(7): 86-98, 113.
- Deng C, Zhao K. 2018. Financial stress and its impact on the business cycle in China[J]. *Journal of Finance and Economics*, 44(7): 86-98, 113. (in Chinese)
- 丁慧,陈颖,卞志村. 2020. 中国金融市场压力指数构建及其宏观经济非线性效应[J]. 现代财经, 40(8): 18-30.
- Ding H, Chen Y, Bian Z C. 2020. The construction of China's financial market stress index and its macroeconomic nonlinear effects[J]. *Modern Finance and Economics*, 40(8): 18-30. (in Chinese)
- 赖娟,吕江林. 2010. 基于金融压力指数的金融系统性风险的测度[J]. 统计与决策, (19): 128-131.
- Lai J, Lyv J L. 2010. Measurement of financial systemic risk based on financial stress index[J]. *Statistics and Decision*, (19): 128-131. (in Chinese)
- 马勇. 2011. 系统性金融风险: 一个经典注释[J]. 金融评论, (4): 1-17, 123.
- Ma Y. 2011. Systemic financial risk: A classical note[J]. *Chinese Review of Financial Studies*, (4): 1-17, 123. (in Chinese)
- 马勇,黄科. 2019. 金融压力指数及其政策应用: 基于中国的实证分析[J]. 金融监管研究, (7): 1-17.
- Ma Y, Huang K. 2019. Financial stress index and its policy applications: An empirical analysis based on the Chinese economy [J]. *Financial Regulation Research*, (7): 1-17. (in Chinese)
- 苗子清. 2020. 中国金融压力的测度和时变特征研究——基于 MIMIC 和 MS-AR 模型的分析[J]. 价格理论与实践, (9): 102-106.
- Miao Z Q. 2020. Research on the measurement and time-varying characteristics of China's financial pressure—Based on the analysis of MIMIC and MS-AR models[J]. *Price: Theory & Practice*, (9): 102-106. (in Chinese)
- 苗子清,张卓群. 2020. 基于大数据方法的中国系统性金融风险预警研究[J]. 经

- 济论坛,(12): 5-17.
- Miao Z Q, Zhang Z Q. 2020. Research on China's systematic financial risk early-warning based on big data methods [J]. *Economic Tribune*, (12): 5-17. (in Chinese)
- 苗子清, 张涛, 党印. 2021. 中国银行体系系统性金融风险传染研究——基于24家A股银行的大数据与机器学习分析[J]. *金融评论*, 13(5): 58-74, 124-125.
- Miao Z Q, Zhang T, Dang Y. 2021. Systemic risk and contagion in China's banking system—Big data and machine learning analysis with 24 A-share listed banks [J]. *Chinese Review of Financial Studies*, 13(5): 58-74, 124-125. (in Chinese)
- 清华大学国家金融研究院金融与发展研究中心课题组. 2019. 中国系统性金融压力的监测[J]. *国际金融研究*, (12): 3-12.
- Center for Finance and Development, Tsinghua National Institute of Financial Research. 2019. Research on monitoring systemic financial stress in China [J]. *Studies of International Finance*, (12): 3-12. (in Chinese)
- 尚玉皇, 郑挺国. 2018. 中国金融形势指数混频测度及其预警行为研究[J]. *金融研究*, (3): 21-35.
- Shang Y H, Zheng T G. 2018. The mixed frequency measuring of Chinese FCI and its risk warning behavior [J]. *Journal of Financial Research*, (3): 21-35. (in Chinese)
- 王艺枘, 陈磊, 孟勇刚. 2019. 数据发布下的服务业景气实时预测[J]. *统计与决策*, 35(21): 30-34.
- Wang Y C, Chen L, Meng Y G. 2019. Real-time forecast of service industry boom under data release [J]. *Statistics and Decision*, 35(21): 30-34. (in Chinese)
- 肖争艳, 任梦瑶. 2021. 媒体风险感知与系统性金融风险预警[J]. *财经问题研究*, (9): 63-74.
- Xiao Z Y, Ren M Y. 2021. Media risk perception and early warning of systemic financial risk [J]. *Research on Financial and Economic Issues*, (9): 63-74. (in Chinese)
- 许涤龙, 陈双莲. 2015. 基于金融压力指数的系统性金融风险测度研究[J]. *经济学动态*, (4): 69-78.
- Xu D L, Chen S L. 2015. Research on the measurement of systemic financial risk: Based on financial stress index [J]. *Economic Perspectives*, (4): 69-78. (in Chinese)
- 徐国祥, 李波. 2017. 中国金融压力指数的构建及动态传导效应研究[J]. *统计研究*, 34(4): 59-71.

- Xu G X, Li B. 2017. Study on the construction of China's financial stress index and its dynamic transmission effect [J]. *Statistical Research*, 34(4): 59-71. (in Chinese)
- 张勇, 彭礼杰, 莫嘉浩. 2017. 中国金融压力的度量及其宏观经济的非线性效应 [J]. *统计研究*, 34(1): 67-79.
- Zhang Y, Peng L J, Mo J H. 2017. The measurement of finance stress and nonlinear effect on macroeconomic activity in China [J]. *Statistical Research*, 34(1): 67-79. (in Chinese)
- 郑金麟, 张业圳, 谢八妹. 2019. 我国系统性金融风险的衡量与识别 [J]. *金融监管研究*, (12): 54-65.
- Zheng J L, Zhang Y Z, Xie B M. 2019. The measurement and prediction of China's systemic risk [J]. *Financial Regulation Research*, (12): 54-65. (in Chinese)
- Aruoba S B, Diebold F X, Scotti C. 2009. Real-time measurement of business conditions [J]. *Journal of Business & Economic Statistics*, 27(4): 417-427.
- Balakrishnan R, Danninger S, Tytell I, et al. 2009. The transmission of financial stress from advanced to emerging economies [R]. International Monetary Fund Working Paper No. 09/133.
- Bloom N. 2009. The impact of uncertainty shocks [J]. *Econometrica*, 77(3): 623-685.
- Brochado A. 2020. Google search based sentiment indexes [J]. *IIMB Management Review*, 32(3): 325-335.
- Da Z, Engelberg J, Gao P J. 2015. The sum of all FEARS investor sentiment and asset prices [J]. *The Review of Financial Studies*, 28(1): 1-32.
- Gauthier C, Graham C, Liu Y. 2004. Financial conditions indexes for Canada [R]. Bank of Canada Working Paper 04-22.
- Goodhart C A E, Hofmann B. 2001. Asset prices, financial conditions and the transmission of monetary policy [R]. Federal Reserve Bank of San Francisco Working Paper.
- Hakkio C S, Keeton W R. 2009. Financial stress: What is it, how can it be measured, and why does it matter? [J]. *Economic Review, Federal Reserve Bank of Kansas City*, 94(2): 5-50.
- Holló D, Kremer M, Lo Duca M. 2012. CISS-A composite indicator of systemic stress in the financial system [R]. European Central Bank Working Paper.
- Illing M, Liu Y. 2006. Measuring financial stress in a developed country: An application to Canada [J]. *Journal of Financial Stability*, 2(3): 243-265.
- International Monetary Fund. 2002. Financial soundness indicators: Analytical aspects

- and country practices[R]. International Monetary Fund Occasional Paper.
- Irresberger F, König F E, Weiß G N F. 2017. Crisis sentiment in the U. S. insurance sector[J]. *Journal of Risk and Insurance*, 84(4): 1295-1330.
- Kaufman G G. 1996. Bank failures, systemic risk, and bank regulation[R]. Federal Reserve Bank of Chicago Working Paper.
- Kibritcioglu A. 2002. Excessive risk-taking, banking sector fragility, and banking crises [R]. University of Illinois at Urbana-Champaign Working Paper, No 02-0114.
- Kliesen K L, Smith D C. 2010. Measuring financial market stress [J]. *Economic Synopses*, (2): 1-2.
- Kostopoulos D, Meyer S, Uhr C. 2020. Google search volume and individual investor trading[J]. *Journal of Financial Markets*, 49: 100544.
- Nyman R, Kapadia S, Tuckett D. 2021. News and narratives in financial systems: Exploiting big data for systemic risk assessment[J]. *Journal of Economic Dynamics & Control*, 127: 104119.
- Van den End J W. 2006. Indicator and boundaries of financial stability [R]. Nederlandsche Bank Working Paper.
- Van Roye B. 2011. Financial stress and economic activity in Germany and the Euro area [R]. Kiel Working Paper.

Real-time Monitoring of China's Financial Stress —Evidence Based on Mixed Frequency Big Data Dynamic Factor Model

Yin Dang¹ Ziqing Miao² Tao Zhang³

(1. China University of Labor Relations; 2. Postdoctoral Research Station, Orient Securities Company Limited;
3. Faculty of Economics, University of Chinese Academy of Social Sciences)

Abstract Preventing and resolving systemic financial risk is of great significance to maintaining financial security. The key issue is to accurately describe and monitor systemic financial risk in real time. Based on the mixed frequency dynamic factor model, this paper constructs a daily frequency China's Financial Stress Index (FSI) by comprehensively using traditional financial statistics and Internet search big data to monitor China's systemic financial risks in real time. The research shows that the constructed FSI can accurately measure and monitor domestic systemic financial risk, and the phased change characteristics of the index and the identification results of regime state are highly consistent with the actual evolution of systemic financial risk. The uncertainty of expectation and risk perception of economic subjects are the main sources of financial

stress, and China's financial stress has strong sustainability. The introduction of big data indicator can significantly improve the estimation of FSI model and promote the prediction effect of FSI on macroeconomic variables. The FSI on "high level" regime state is better in predicting month-on-month CPI growth, while the FSI on "low level" regime state is better in predicting GDP growth. In the future, regulatory authorities need to continue to optimize the financial risk monitoring and early warning system, improve monitoring capabilities, and reasonably guide market expectations.

JEL Classification C50, G10