

风险偏好能否成为我国金融风险的前瞻性指标？^{*}

——来自前沿机器学习方法的新证据

杨子晖 李东承 陈雨恬

摘要：近年来，全球金融市场不确定性攀升、金融系统震荡加剧，如何完善金融机构的风险预警体系、及时防范化解金融风险隐患，引起了我国监管机构的高度重视。2007年次贷危机与2023年硅谷银行破产相继表明，银行风险偏好的大幅上升是信贷扩张乃至金融风险加速积聚的重要原因。有鉴于此，本文基于银行业资产负债表数据，准确测度我国银行业风险偏好，并采用前沿的机器学习方法对金融风险展开预测。分析结果显示，风险偏好是我国金融风险的前瞻性指标，其中，大型商业银行的规模加权风险偏好较高，而城商行、农村金融机构的单位资产风险偏好相对更高。与此同时，在高风险时期，金融机构的风险偏好也会加剧金融市场异常波动，甚至进一步诱发金融风险。此外，前沿的机器学习方法能够对我国银行风险进行稳定、有效的预测。而且，较之银行杠杆等传统监管指标，基于风险偏好指标构建预测模型时，其样本外预测拟合优度出现了明显的提升。在此基础上，本文提出了基于银行风险偏好实施差异化管理、结合机器学习方法加强金融风险实时监控的若干政策建议，从而有助于我国提高金融系统稳定性，完善全方位、前瞻性的系统性金融风险预警体系。

关键词：银行风险偏好 金融风险 风险预测 机器学习

一、引言

近年来，国际政治经济局势持续动荡，新冠疫情、产业链重构等风险事件致使全球金融市场不确定性攀升，金融系统剧烈震荡。例如，2023年3月，美国硅谷银行被联邦储蓄保险公司清算管理。究其原因，较之其他银行，硅谷银行偏好于向尚未盈利、现金流相对不足的高科技初创企业提供风险贷款，且长期债券投资占比较大，流动资金易在受到负面冲击时快速枯竭，加剧破产风险。与此同时，我国部分高风险偏好银行的风险持续积聚。其中，锦州银行自2015年上市后，持续采取较为激进的经营策略，2017年、2018年的贷款增长率高达69.65%与72.33%，存贷比也由2016年的40.36%攀升至2019年的123.42%，这就意味着，该银行负债结构稳定性较低，风险偏好相对较高。因此，受高风险偏好影响，锦州银行的风险敞口迅速提升，其2019年的核心一级资本充足率仅为5.15%，不良贷款率也高达7.70%，违约风险迅速积聚。正因如此，如何完善金融机构的风险监管体系、及时防范化解金融风险隐患，一直是我国监管机构高度重视的核心问题。对此，2022年10月16日，习近平总书记在中国共产党第二十次全国代表大会上强调“我国发展进入战略机遇和风险挑战并存、不确定难预料因素增多的时期，各种‘黑天鹅’、‘灰犀牛’事件随时可能发生。我们必须增强忧患意识，坚持底线思维，做到居安思危、未雨绸缪”，并提出“加强和完善现代金融监管，强化金融稳定保障体系，依法将各类金融活动全部纳入监管，守住不发生系统性风险底线”。由此可见，结合风险偏好对我国银行风险展开前瞻性预测，并及时缓释化解系统性金融风险，将有助于我们妥善应对国际外溢冲击、提高我国金融系统稳定性，为国民经

收稿时间：2023-1-5；反馈外审意见时间：2023-6-9、2023-10-17；拟录用时间：2024-5-13。

^{*} 本研究得到国家社会科学基金青年项目“银行业系统性金融风险的测度与防范对策研究”（基金号：22CJY004）的资助。感谢匿名评审专家的宝贵意见，当然文责自负。李东承为本文通讯作者。

济的高质量发展夯实稳定的金融基础。

相关研究指出,金融危机对经济发展存在显著且持久的负面影响,并可能导致永久性的经济金融损失(法塔斯、萨默斯,2018)。其中,银行业是金融系统的核心部门,与其他金融机构、金融市场、实体企业间均存在紧密关联。银行业的波动往往会放大金融系统受到的外部冲击,加剧金融风险隐患(巴伦等,2021;杜阿尔特、艾森巴赫,2021)。在我国,由银行主导的间接融资更是各企业融资的主要渠道(杨子晖、李东承,2018),据中国人民银行公布的社会融资规模存量统计数据,截至2023年12月末,我国间接融资占比仍高达70%。此外,值得一提的是,美国次贷危机的爆发也与银行的高风险偏好紧密相关。具体而言,2002~2006年间,随着美国房价的持续上涨、美联储的连续多次降息并推行“低首付”“零首付”购房方式,美国各金融机构的风险偏好迅速提升。银行大规模地向信用评级较低且没有足够偿还能力的借款人发放次级贷款,致使金融杠杆大幅攀升、风险隐患持续加剧,并最终诱发2007年美国次贷危机乃至2008年国际金融危机,给全球经济带来严重冲击,其中美国、英国、德国2009年的国内生产总值增长率仅为-2.60%、-4.61%、-5.69%。由此可见,在现阶段国际经济金融形势严峻复杂的背景下,结合风险偏好厘清我国银行风险的驱动因素、构建前瞻性的系统性金融风险预警体系,将有助于我们及时防范化解风险、维护国家金融安全。

该领域的早期研究认为,信贷的过度扩张可能是银行业危机的主要根源,金融机构的信贷水平会对金融风险的积聚产生显著影响(迈恩、苏非,2009;舒拉里克、泰勒,2012)。具体而言,相关文献指出,过度扩张的信贷往往会对房地产等实体经济造成严重冲击(迈恩、苏非,2022),加剧商业周期与经济周期波动(迈恩等,2020),增加金融机构风险敞口,加速风险积聚,引发系统性金融风险。然而,各金融机构的信贷结构存在明显的异质性特征,仅采用信贷规模指标难以对金融风险进行前瞻性预测(科英布拉等,2022)。在此基础上,相关研究剖析了个体异质性对金融稳定的影响,并基于金融杠杆、资本短缺等视角对潜在风险展开估计(布朗利斯、恩格尔,2017;杜阿尔特、艾森巴赫,2021)。

进一步地,信贷规模与杠杆水平的提高可归因于两类不同的渠道:一方面,实体经济投资机会的增多,会从需求端明显抬升金融机构杠杆;另一方面,资金成本的降低,也会推动杠杆上行,导致更高的银行业风险(德尔阿里恰等,2014)。然而,上述两种信贷扩张模式可能导致截然不同的经济后果(里克特等,2021)。具体而言,前者代表了宏观经济基本面的向好,而后者引发的杠杆提高则意味着金融风险的积聚。更重要的是,各金融机构也会通过监管套利等方式规避杠杆率与资本充足率要求(蔡等,2020),使得杠杆水平难以准确反映银行业的潜在风险水平。随着该领域研究的不断深入,相关文献指出,银行业风险偏好的上升或是金融风险加速积聚的重要原因(科英布拉等,2022)。具体而言,在信贷繁荣时期,由于货币储蓄充足、货币政策趋于宽松,银行等金融中介机构的资金成本显著下降。此时,高风险偏好银行市场份额的显著提升,将致使金融风险不断积聚(科英布拉、雷伊,2024)。而当市场大幅震荡、外部环境恶化、同业竞争加剧时,金融机构为了维持资本回报率,不得不放松自身的信贷约束,构建高风险投资组合。在此背景下,银行业采取的高风险偏好行为,也极易加剧金融风险隐患。除此之外,相关研究指出,银行风险的提升将导致企业违约风险积聚(荆等,2022),使风险从银行业向实体经济快速传导(霍多罗夫-赖克、法拉托,2022)。因此,采用银行业风险偏好指标,能够更为准确地捕捉金融风险的变动趋势^①。例如,2017年中国银行业监督管理委员会(现合并为国家金融监督管理总局)行政处罚信息公开表显示,恒丰银行存在“理财资金投资非标准化债权资产余额超比例”“单一集团客户授信集中度超过监管规定比例”“违反国家规定从事投资活动”等高风险的违法违规行为。而此类为攫取超额利润的高风险偏好行为,更是致使恒丰银行信贷资产质量大幅恶化,其2018年不良贷款率甚至高达28.44%,并导致该银行于2019年“暴雷”,对我国金融稳定产生冲击。

纵观该领域的研究可以发现,第一,银行部门是中国金融系统的核心部门,其经由信贷关联与各类实体经济活动紧密相连(霍多罗夫-赖克、法拉托,2022),这使得深入剖析银行风险的影响因素成为缓释金融风险、保障金融高质量发展的关键环节。然而,相关实证研究指出,银行资本充足率等传统风险监管指标,可能无法预测各银行的金融风险(阿布-埃尔-苏德,2016)。而银行的风险偏好则可能是其风险积聚的重要驱

动因素(科英布拉等,2022)。准确测度各银行的风险偏好、有效评估系统性风险水平,将有助于化解潜在金融风险隐患,实现对高风险金融机构的“精准拆弹”。第二,现有理论研究表明,银行风险偏好在一定程度上反映了潜在的金融风险隐患(科英布拉等,2022)。但我国银行业在准入门槛、监管政策、银行数量、产品种类等方面与发达经济体存在明显差异,银行业风险偏好这一指标在我国的适用性仍有待检验。与此同时,国内研究较少从银行风险偏好的角度深入剖析金融风险的影响因素。因此,在准确测度各银行风险偏好的基础上,实证检验我国银行风险偏好对金融风险的作用影响,将有助于更精准、有效地剖析我国银行风险的驱动因素。第三,现有文献大多在传统分析框架下采用回归分析、因果检验等方法预测金融风险,而忽略了金融风险存在的非线性特征与非对称特征。同时,值得注意的是,由于存在“维度诅咒”问题,传统方法难以有效处理、分析高维数据集(高等,2019),而在数据处理中引入降维方法又将导致大量的信息损失,这明显制约了金融风险预测的准确性与前瞻性。随着该领域研究的不断深入,最新研究指出,机器学习方法能更好地捕捉到自变量与因变量间的非线性关系(陈等,2021;李等,2020)。前沿的机器学习方法能在大量解释变量中提取有效特征,而此类“数据驱动”的建模方式也能充分减轻模型设定偏误带来的影响,从而克服上述传统方法的局限性。因此,结合前沿的机器学习方法,准确预测我国银行业的金融风险水平,对前瞻性地防控金融风险、切实维护我国金融安全有着重要的学术价值。第四,现有研究通常基于单一方法对金融风险展开建模分析,而相关研究指出,各方法的预测效力存在明显的差异(莱波尔德等,2022)。因此,在统一框架下就各模型对金融风险的样本外预测能力展开全面的对比分析,有助于我们结合实际经济运行条件,适时、适度调整风险防控政策。最后,美国次贷危机、硅谷银行等金融机构“暴雷”相继表明,银行为攫取超额利润采取的高风险偏好行为,易导致信贷资产质量恶化、杠杆过度抬升,引发金融风险积聚,甚至造成严重的经济后果。因此,现阶段结合风险偏好这一重要指标,深入考察金融风险的驱动因素并对其展开前瞻性的预测,显然具有重要的现实意义,这将有助于监管机构对银行业实施分类差异化管理,进一步完善我国金融风险防控体系。

有鉴于此,本文创新性地基于银行业风险偏好这一研究视角,采用前沿的机器学习方法对我国银行业金融风险展开前瞻性预测。具体而言,首先,我们采用最新发展的银行业风险偏好指标(科英布拉等,2022),准确衡量了我国各银行在2009~2020年间的风险偏好。其次,本文结合恒丰银行、包商银行等具体案例,深入对比分析风险偏好与传统监管指标对金融风险的驱动影响。与此同时,本文进一步采用面板分位数回归方法,剖析不同分位数水平下,风险偏好指标对银行风险的异质性影响。再次,我们结合前沿的机器学习方法,尝试对银行业金融风险展开有效预测,探究银行业风险偏好指标在风险前瞻性预测中的角色与作用。最后,我们还在统一框架下,对各模型的预测能力进行深入的对比分析,准确甄别最优风险预测模型。此外,在得出富有启发意义结论的基础上,我们提出了妥善应对国际外溢冲击、构建全方位、前瞻性的金融风险防范体系的若干建议。

二、研究方法 with 数据说明

(一) 银行业风险偏好的估计

本文借鉴科英布拉等(2022)提出的银行业风险偏好估计方法,结合银行业资产负债率的分布情况,刻画各银行的风险偏好水平。具体而言,假设每家银行都是风险中性的,且受到在险价值(Value at Risk, VaR)的约束,并希望实现利润最大化。这就意味着,银行*i*在选择利润最大化投资策略的同时,其净资产收益率为负的概率需小于等于特定的概率 $\alpha_{i,t}$,较大的 $\alpha_{i,t}$ 意味着银行的风险承受意愿较高,而较低的 $\alpha_{i,t}$ 则表示银行投资策略较为保守。我们把银行面临的在险价值约束表示如下:

$$P(Equity_{i,t+1} < Equity_{i,t}) \leq \alpha_{i,t} \quad (1)$$

其中, $Equity_{i,t}$ 表示银行*i*在*t*期的初始权益资本, $Equity_{i,t+1}$ 表示银行*i*在*t+1*期的权益资本。进一步地,我们假设每家银行资产 $Asset_{i,t}$ 的收益 $r_{i,t+1}^{Asset}$ 是独立同分布的随机变量 $X_{i,t+1}$,随机变量 $\ln X_{i,t+1}$ 的条件均值和方差分别为

$\mu_{X,t}$ 和 $\sigma_{X,t}^2$, 银行债务 $Debt_{i,t}$ 的资金成本为 r_t^{Debt} 。由此得到银行 i 在 $t+1$ 期的权益资本:

$$Equity_{i,t+1} = Equity_{i,t} + Asset_{i,t} r_{i,t+1}^{Asset} - Debt_{i,t} r_t^{Debt} \quad (2)$$

我们定义 $X_{i,t+1}^{e} = \exp(\mu_{X,t})$, 以刻画银行 i 在 t 期的杠杆 $Leverage_{i,t}$ 与其风险承担意愿 $\alpha_{i,t}$ 间的关联, 即:

$$Leverage_{i,t} = \frac{Asset_{i,t}}{Equity_{i,t}} = \frac{r_t^{Debt}}{r_{i,t+1}^{Debt} - X_{i,t+1}^{e} \Phi_i(\alpha_{i,t})} \quad (3)$$

其中, $\Phi_i(\cdot)$ 为 $X_{i,t+1}/X_{i,t}^{e}$ 的逆累积分布函数, 根据上式可知, 杠杆和银行风险偏好之间的映射关系由预期资产收益率 ($X_{i,t+1}^{e}$)、利率 (r_t^{Debt})、收益的不确定性 ($\Phi_i(\cdot)$) 等宏观经济基本面因素决定。式 (3) 可以用银行资产负债率重新表示为:

$$LOAR_{i,t} = \frac{Debt_{i,t}}{Asset_{i,t}} = 1 - \frac{1}{Leverage_{i,t}} = \frac{X_{i,t+1}^{e}}{r_t^{Debt}} \Phi_i(\alpha_{i,t}) \quad (4)$$

式 (4) 表明, 当经济不确定性增加, 即波动率上升 ($\Phi_i(\cdot)$ 下降) 时, 若银行的风险偏好保持不变, 则需要降低资产负债率。但当银行资金成本 (r_t^{Debt}) 相对较低且预期回报的波动性较小时, 风险损失承受意愿更高 (即 $\alpha_{i,t}$ 更大) 的银行将大幅提高资产负债率 ($LOAR_{i,t}$), 以实现利润最大化。科英布拉和雷伊 (2024) 的研究进一步指出, 当市场资金成本与收益的不确定性均较低时, 银行面临的在险价值约束将迅速放松, 使得高风险偏好的中介机构大规模地增加杠杆。这意味着, 随着利率的下降, 银行业资产负债率分布的偏度将大幅提升, 即高风险偏好金融机构所持有的资产比例将在低利率时期明显上升。

为了进一步对模型进行求解, 我们假定随机变量 $\ln X_{i,t+1}$ 服从参数为 $(\mu_{X,t}, \sigma_{X,t}^*)$ 的 Logistic 分布, 其均值和标准差分别为 $\mu_{X,t}$ 和 $\pi \sigma_{X,t}^* / \sqrt{3}$ 。相应地, $X_{i,t+1}/X_{i,t}^{e}$ 将服从参数为 $(0, \sigma_{X,t}^*)$ 的 Log-logistic 分布, 其逆累积分布函数为 $\Phi_i(y) = [y/(1-y)]^{\sigma_{X,t}^*}$ 。进一步假设在险价值的横截面分布服从 $(0, 1)$ 区间内的 Beta 分布: $\alpha_{i,t}/\alpha_{i,t}^{ub} \sim \text{Beta}(\xi_{i,t}, \xi_{r,t})$, 其中, $\alpha_{i,t}^{ub} \leq 1$ 是 t 期 $\alpha_{i,t}$ 的上界, $\xi_{i,t}$ 和 $\xi_{r,t}$ 分别是 Beta 分布的左尾和右尾形态参数。基于以上假设, 资产负债率 $\psi_{i,t}$ 将服从广义 Beta 分布, $\Xi_t = \{\xi_{a,t}, \xi_{b,t}, \xi_{c,t}, \xi_{l,t}, \xi_{r,t}\} = \left\{1/\sigma_{X,t}^*, \frac{X_{i,t+1}^{e}}{r_t^{Debt}} (\alpha_{i,t}^{ub})^{\sigma_{X,t}^*}, \alpha_{i,t}^{ub}, \xi_{i,t}, \xi_{r,t}\right\}$ 。由此, 我们可将资产负债率 $LOAR_{i,t}$ 的概率密度函数表示为:

$$\text{pdf}(\chi | \Xi_t) = \frac{\xi_{a,t} \chi^{\xi_{a,t} \xi_{l,t} - 1} \left[1 - (1 - \xi_{c,t})(\chi/\xi_{b,t})\right]^{\xi_{a,t} - 1}}{\xi_{b,t}^{\xi_{a,t} \xi_{l,t}} \text{Beta}(\xi_{l,t}, \xi_{r,t}) \left[1 + \xi_{c,t} (\chi/\xi_{b,t})\right]^{\xi_{a,t} - \xi_{l,t} + \xi_{r,t}}} \quad (5)$$

其取值范围在 $(0, \xi_{b,t}/(1 - \xi_{c,t}))^{1/\xi_{l,t}}$ 之间, 且 $\xi_{a,t} > 0$ 和 $\xi_{b,t} > 0$ 。据此采用加权最大似然法估计参数 Ξ_t :

$$\hat{\Xi}_t = \arg \max_{\Xi_t} \sum_i w_{i,t} \times \ln \text{pdf}(LOAR_{i,t} | \Xi_t) \quad (6)$$

考虑到银行规模的异质性, 我们在估计单位资产风险偏好 $\hat{\alpha}_{i,t}$ 的过程中, 将对数似然函数按照银行规模进行加权。在估计出广义 Beta 分布参数的 $\hat{\Xi}_t$ 后, 可将观测得到的杠杆倍数 $Leverage_{i,t}$ 代入 (3) 式, 计算各银行隐含的单位资产风险偏好程度:

$$\hat{\alpha}_{i,t} = \alpha(Leverage_{i,t} | \hat{\Xi}_t) = \frac{\hat{\xi}_{c,t} (1 - 1/Leverage_{i,t})^{\hat{\xi}_{a,t}}}{(\hat{\xi}_{c,t})^{\hat{\xi}_{a,t}} + \hat{\xi}_{c,t} (1 - 1/Leverage_{i,t})^{\hat{\xi}_{a,t}}} \quad (7)$$

在求得各家银行的单位资产风险偏好的基础上, 通过银行规模大小进行加权, 我们可得到银行的规模加权风险偏好^②:

$$\hat{\alpha}_{i,t}^{weighted} = \frac{Asset_{i,t} \hat{\alpha}_{i,t}}{\sum_{i=1}^n Asset_{i,t}} \quad (8)$$

(二) 前沿的机器学习模型

1. 梯度提升回归树

在样本量受限的情况下, 传统线性回归模型的自由度将随着自变量的增加而减少。因此, 在高维情况下, 当自变量的数目接近样本量时, 最小二乘估计将出现明显的“过拟合”现象, 使得模型的样本外预测能力下降

(顾等,2020),并且,传统方法较少考虑自变量对因变量的非线性影响。为了克服以上缺陷,本文考虑以回归树模型为基础,结合前沿的机器学习方法展开分析。一个存在 K 片叶子(终端节点)、深度为 L 的树模型可表示为:

$$g(z_{i,t};\theta,K,L)=\sum_{k=1}^K\theta_k1_{\{z_{i,t}\in C_k(L)\}} \quad (9)$$

其中, $C_k(L)$ 是树的第 k 个分区,深度 L 代表所有完整分支中的最大节点数, θ_k 为基于训练集得到的位于第 k 个分区的样本平均值。梯度提升回归树(Gradient Boosted Regression Trees,GBRT)方法的主要思想为,通过递归组合多个“弱学习器”的预测结果生成“强预测模型”,而简单树模型即为梯度提升回归树模型中的“弱学习器”。具体而言,我们构建一个深度为 L 的树 $\mathcal{T}_1$ 来拟合特征向量 $z_{i,t}$,并构建第二棵同样深度为 L 的简单树模型 $\mathcal{T}_2$,以拟合第一棵树模型的残差。此时,第一棵树 $\mathcal{T}_1$ 的预测与第二棵树 $\mathcal{T}_2$ 的预测之和,乘以学习率 $v\in(0,1)$,即为最简单的梯度提升回归树模型的集成预测。类似地,构建另外 $B-2$ 棵树,即可估计出包含 B 棵树的梯度提升回归树模型^③:

$$\hat{g}_{GBRT}(z_{i,t};B,v,L)=\sum_{b=1}^Bv\hat{g}_b \quad (10)$$

2. 随机森林

随机森林(Random Forest)方法采用自助聚合算法(Bagging),集成不同树模型的结果,以得到更稳健的预测模型。简单的自助聚合算法往往随机抽取 B 个样本,并基于每个样本拟合回归树模型,然后取 B 棵树预测值的平均,即:

$$\mathcal{T}_{\text{Bagging}}(z_{i,t};L,B)=\frac{\sum_{b=1}^Bg_b(\theta,K,L)}{B} \quad (11)$$

而自助聚合算法则通过对多个预测求平均值,有效减轻了树模型过拟合的问题,降低了预测方差。进一步地,随机森林在自助聚合算法的基础上,在回归树拟合过程中引入了随机属性选择的过程,从而提升了样本外的预测性能^④:

$$\hat{g}_{RF}(z_{i,t};L,B)=\frac{\sum_{b=1}^B\hat{g}_b(z_{i,t};\hat{\theta}_b,L)}{B} \quad (12)$$

(三)数据说明

本文采用银行业资产负债表数据中的银行总资产、银行资本、银行总负债等指标,估计各银行的风险偏好,样本的时间跨度为2009~2020年,数据来源于国泰安(CSMAR)数据库。同时,本文使用银行业股票的回报率数据计算金融风险指标。此外,我们还借鉴莱波尔德等(2022)的研究,选取了64个企业层面的特征指标,并在此基础上使用了14个银行业专项指标,以及12个代表宏观经济发展状况的指标,结合前沿机器学习全面预测银行业风险^⑤。上述数据的样本时间跨度为2010年1月~2020年12月,数据来源于国泰安与万得(Wind)数据库。表1为本文主要变量的描述性统计结果。对比表1中两类风险偏好的描述性统计结果可知,规模加权风险偏好的标准差、偏度、峰度均高于单位资产风险偏好,这可能是由于我国银行业中各类银行的规模存在显著差异,因此按规模加权后,风险偏好指标的异质性明显提升。

本文在表2中进一步计算了各类指标的变异系数,以考察不同指标的离散程度。表2表明,较之银行业杠杆倍数、资本充足率等传统指标,在各类银行中,两类风险偏好指标的变异系数均相对更高,表明其存在更为明显的异质性特征。这就意味着,银行的风险偏好指标可能比传统指标信息含量更高,将有助于我们对系统性金融风险开展更具前瞻性的预测。

表1 主要变量的描述性统计

	边际期望 损失 (MES)	在险价值 (VaR)	单位资产 风险偏好 (比例)	规模加权 风险偏好 (比例)	杠杆倍 数(倍)	资本充足率 (百分比)	一级资本 充足率 (百分比)	核心一级资 本充足率 (百分比)
均值	0.022	0.026	0.084	0.063	14.764	13.153	10.554	9.906
中位数	0.020	0.022	0.047	0.018	14.454	13.070	10.350	9.470
标准差	0.012	0.018	0.101	0.120	2.671	1.666	1.590	1.548
25%分位数	0.013	0.017	0.019	0.001	12.676	11.890	9.410	8.710
75%分位数	0.028	0.030	0.103	0.079	16.375	14.280	11.560	10.920
偏度	1.911	5.712	2.172	6.079	1.251	0.371	0.392	0.760
峰度	14.113	54.556	8.154	62.021	6.825	2.921	2.860	3.011

注:对规模加权风险偏好进行描述性统计时,为了使其量级与单位资产风险偏好相同,我们将其与银行样本数量相乘;按该领域研究惯例,边际期望损失与在险价值取负,数值越高表示金融风险越大。

三、实证结果与分析

(一)我国银行业风险偏好的测度

银行业是金融系统的核心部门,准确衡量银行业的潜在风险、及时压降风险敞口是维护国家金融安全的重要前提。然而,最新研究指出,杠杆水平可能由不同因素驱动,一方面,金融中介机构资金成本降低、信贷供给大幅增加,将推动杠杆上行,引发金融风险积聚;另一方面,技术进步与生产力的提升也可能在一定程度上提升社会信贷需求,使得银行杠杆明显抬升(戈顿、奥多内斯,2020)^⑥。因此,仅采用银行杠杆倍数或是资本充足率的传统预警模型,可能出现显著偏差。有鉴于此,本文测度了我国2009~2020年的银行业风险偏好,深入探究金融风险的变动趋势。

图1展示了近年来,我国银行业风险偏好与系统性金融风险测度指标的演变态势。图1显示,截至2013年第三季度,我国银行业风险偏好相对较低,均未超过0.05。究其原因,在2013年前,我国银行业的同业竞争程度较低、金融科技发展相对迟缓且风险厌恶水平较高,金融机构所从事的高风险业务较少。然而,由图1,我们可以清楚地发现,各银行的风险偏好在2013年第四季度大幅攀升,而在2015年“股市异常波动”时期更是始终居于高位。究其原因,随着2013年互联网金融理财热潮的兴起,以及“余额宝”等高收益的活期资金管理服务产品陆续上线,我国银行业的竞争压力开始逐步显现、同业竞争加剧,部分金融机构开始偏好于从事高风险业务,以维持利润增长。与此相对应的,较之风险偏好指标,系统性金融风险测度指标的变动则相对滞后,边际期望损失与在险价值在2015年第三季度才升至峰值。这就意味着,边际期望损失等指标往往反映了金融风险的同期或滞后变动,因此难以对其进行前瞻性预测,而银行风险偏好指标则能较好地对风险事件提前预警。这可能是由于,同业竞争的加剧以及“降息”“降准”等政策的实施导致部分银行风险偏好提升,使得银行在资金相对充裕的情况下主动寻求更高的资产回报率。例如,2014~2015年间,通过伞形信托、场外配资等各类新型金融工具,大量银行自有资金及理财资金直接或间接地进入了我国A股市场,从而在一定程度上加速了股市从“慢牛”到“杠杆牛”的转变,致使金融风险加速积聚,并最终引发了股市异常波动。由此可见,准确衡量银行业风险偏好,对风险展开前瞻性预测,将有助于我们防范化解潜在金融风险隐患、维护国家金融安全。

在此基础上,本文进一步探究我国不同银行风险偏好的时变特征。表3展示了2009~2020年间,按规模加权与未加权的银行风险偏好前十位的排序结果。表3表明,各银行的风险偏好表现出明显的个体异质性,这也与该领域的研究相一致,即在不同金融机构间,由于规模、企业文化、政府监管、管理者偏好等因素均存在差异,各机构的风险偏好也通常表现出明显不同(巴哈特等,2015;穆鲁齐杜-丹姆察等,2019;里格等,2015;布兰道-马克斯等,2020;哈

表2 风险偏好指标与传统指标的变异系数

	单位资产 风险偏好	规模加权 风险偏好	杠杆倍数	资本充足率	一级资本 充足率	核心一级资 本充足率
大型商业银行	0.978	1.247	0.148	0.112	0.135	0.118
股份制商业银行	1.019	1.216	0.194	0.115	0.142	0.117
城市商业银行	1.460	2.127	0.137	0.096	0.096	0.125
农村金融机构	1.279	1.690	0.115	0.101	0.119	0.123
总体样本	1.212	1.918	0.181	0.127	0.151	0.156

注:变异系数(Coefficient of Variation)等于标准差除以平均值,刻画了分布的离散程度。变异系数越大,样本的离散程度越高。




图1 银行业风险偏好与金融风险

注:(1)图中灰色柱形表示银行业的总风险偏好;实线与虚线则分别表示边际期望损失和在险价值。(2)坐标轴的左轴表示风险偏好,右轴表示金融风险。

根多夫等,2021)。其中,表3的Panel A显示,在对风险偏好进行规模加权调整后,国有大型商业银行的风险偏好相对更高,而农业银行与邮政储蓄银行通常居于前两位。究其原因,大型商业银行规模较大,在我国银行业中处于核心地位,因此,经规模加权的银行风险偏好也往往更高。相对应地,近年来,为了更好地防控大型金融机构的风险,我国针对上述系统重要性银行提出了一系列附加监管规定,例如根据2021年12月施行的《系统重要性银行附加监管规定(试行)》要求,农业银行、工商银行等国有大型商业银行受到了最为严格的监管约束,需额外满足1%的附加资本充足率要求。

与此同时,表3的Panel B则展示了2009~2020年样本中各机构未加权风险偏好的排序情况,从中可以发现,与Panel A中结果不同,城商行、农村金融机构的单位资产风险偏好相对更高。这也部分解释了为何包商银行、锦州银行等城商行,以及河南禹州新民生村镇银行、上蔡惠民村镇银行、柘城黄淮村镇银行等农村金融机构频频爆发局部金融风险事件。因此,我国应持续完善差异化风险防控机制,加强对风险偏好过高的城商行、农村金融机构的监管力度,稳妥开展风险的早期干预与处置工作,及时防范化解中小金融机构风险隐患、提升金融系统稳定性。

在此基础上,本文依据银行类型,深入剖析各类银行风险偏好的特征。图2显示,大型商业银行与股份制商业银行的相对规模较大,加权风险偏好普遍较高,而单位资产风险偏好则较低,大多位于图中第四象限。但值得注意的是,对于资产规模较大的邮储银行而言,其单位资产的风险偏好也相对较高,易成为我国银行系统的薄弱环节。万得统计数据显示,2021年5月~2022年11月间,邮储银行共计受到了原中国银行保险监督管理委员会(现已调整为国家金融监督管理总局)381次违规处罚,总罚款金额高达7741.84万元。相关研究指出,业务不合规、易受到处罚的金融机构往往将产生更高的违约风险(布罗兹、科琴达,2022),因此,我国监管机构应进一步加强银行业务合规性的事前培训与日常监督,从而及时识别高风险违规行为,有效防范银行风险偏好过高诱发金融风险积聚。此外,由图2可知,城商行与农

表3 2009~2020年银行风险偏好排序结果

Panel A: 规模加权银行风险偏好排序										
	第一位	第二位	第三位	第四位	第五位	第六位	第七位	第八位	第九位	第十位
2009年	农业银行	工商银行	浦发银行	华夏银行	广发银行	招商银行	光大银行	建设银行	交通银行	平安银行
2010年	农业银行	华夏银行	工商银行	兴业银行	交通银行	建设银行	中国银行	渤海银行	平安银行	北京农商
2011年	农业银行	工商银行	兴业银行	中国银行	建设银行	交通银行	浦发银行	华夏银行	招商银行	光大银行
2012年	农业银行	工商银行	兴业银行	民生银行	光大银行	建设银行	恒丰银行	华夏银行	中国银行	浦发银行
2013年	邮储银行	农业银行	工商银行	兴业银行	建设银行	中国银行	浦发银行	华夏银行	广发银行	恒丰银行
2014年	邮储银行	农业银行	兴业银行	工商银行	建设银行	民生银行	浦发银行	广发银行	华夏银行	中信银行
2015年	邮储银行	农业银行	兴业银行	中信银行	浦发银行	广发银行	招商银行	建设银行	浙商银行	民生银行
2016年	邮储银行	农业银行	兴业银行	民生银行	广发银行	浦发银行	浙商银行	中信银行	建设银行	江苏银行
2017年	邮储银行	农业银行	广发银行	兴业银行	民生银行	渤海银行	盛京银行	浙商银行	浦发银行	宁波银行
2018年	邮储银行	农业银行	兴业银行	交通银行	渤海银行	中国银行	民生银行	工商银行	浙商银行	江苏银行
2019年	邮储银行	农业银行	兴业银行	中国银行	江苏银行	建设银行	工商银行	交通银行	杭州银行	中信银行
2020年	邮储银行	农业银行	建设银行	中信银行	工商银行	浙商银行	民生银行	兴业银行	中国银行	交通银行
Panel B: 单位资产银行风险偏好排序										
	第一位	第二位	第三位	第四位	第五位	第六位	第七位	第八位	第九位	第十位
2009年	北京农商	长城华西	晋城银行	广发银行	平安银行	华夏银行	泰安银行	长沙银行	大同银行	农业银行
2010年	华夏银行	四川天府	盛京银行	渤海银行	长城华西	攀枝花行	北京农商	厦门银行	大同银行	哈尔滨行
2011年	大同银行	厦门国际	邢台银行	龙江银行	河北银行	北部湾行	北京农商	厦门银行	恒丰银行	长沙银行
2012年	大同银行	宁波通商	恒丰银行	渤海银行	大连银行	长阳农商	岳西农商	北京农商	厦门国际	四川天府
2013年	六安农商	邮储银行	厦门国际	大同银行	恒丰银行	渤海银行	厦门银行	大连银行	北京农商	秦皇岛行
2014年	邮储银行	成都农商	渤海银行	厦门国际	浙商银行	恒丰银行	启东农商	厦门银行	广发银行	广州银行
2015年	广东农信	邮储银行	保定银行	营口沿海	渤海银行	广州银行	浙商银行	泰安银行	大同银行	成都农商
2016年	广东农信	保定银行	邮储银行	六安农商	邢台银行	泰安银行	淮海村镇	渤海银行	广州银行	承德银行
2017年	广东农信	六安农商	邢台银行	大同银行	邮储银行	渤海银行	长阳农商	盛京银行	长沙银行	邯郸银行
2018年	广东农信	长阳农商	大同银行	邮储银行	邯郸银行	彭城农商	简阳农商	渤海银行	承德银行	庐江农商
2019年	揭东农商	长阳农商	大同银行	秦皇岛行	庐江农商	邮储银行	汉口银行	国民村镇	顺昌联社	邯郸银行
2020年	灵石农商	国民村镇	秦皇岛行	太湖农商	阜新银行	庐江农商	临泉农商	富民村镇	汉口银行	明溪联社

注:名字过长的银行以简称代替,其中“遵义红花岗富民村镇银行”简称为“富民村镇”,“桂林国民村镇银行”简称为“国民村镇”,“安徽宿州淮海村镇银行”简称“淮海村镇”。




图2 银行业规模加权风险偏好与单位资产风险偏好对比

注:(1)图中按照规模加权风险偏好与单位资产风险偏好的全样本排序将所有银行划分到4个象限中,图中横轴表示银行的规模加权风险偏好,纵轴表示银行的单位资产风险偏好,坐标轴交界处即为中位数;(2)大型商业银行、股份制银行、城市商业银行、农村金融机构以及其他金融机构分别用圆形、六角星、五角星、菱形以及三角形标记;(3)图中节点半径表示银行规模。




图3 恒丰银行与包商银行的风险偏好走势图

注：(1)图(a)中灰色柱形(对应左侧纵轴)表示恒丰银行风险偏好，黑色折线(对应右侧纵轴)表示恒丰银行风险偏好与股份制银行平均风险偏好之比，2017~2018年恒丰银行未公布年报，图中相应留空；(2)图(b)中灰色柱形表示包商银行的风险偏好，包商银行于2017年停止披露年报，因此数据截至2017年第三季度。

村金融机构数目较多、分布相对分散、风险偏好强弱不一，同样表明应据此采取差异性的监管措施。

进一步地，本文对近年来被依规接管、处置的恒丰银行与包商银行展开案例分析^⑦。图3(a)中展示了恒丰银行近年来的风险偏好走势，我们可以发现，早在2011年第四季度，恒丰银行的风险偏好就已大幅提升，其风险偏好超过股份制商业银行平均风险偏好的2倍有余。与此相对应的，恒丰银行的高风险偏好行为诱发了“理财资金投资非标准化债权资产余额超比例”“单一集团客户授信集中度超过监管规定比例”“违反国家规定从事投资活动”等一系列违规、违法行为，信用风险敞口大幅提升。而在2019年恒丰银行正式改革重组后，其风险偏好也明显降低。

相类似地，包商银行于2017年停止公布年报，并于2019年5月24日正式被中国人民银行与中国银行保险监督管理委员会实行接管。因此，我们同样在图3(b)中展示了包商银行的风险偏好走势，测度结果显示，自2013年第四季度以来，包商银行的风险偏好就已迅速攀升，且直至2017年停止公布年报时，始终处于高点。由此可见，银行业风险偏好指标能够对风险事件进行提前预警，也能成为系统性风险预测的前瞻性指标。

(二)银行业风险偏好与金融风险

最新研究指出，银行风险偏好程度越高，其未来违约的可能性越大(科英布拉等，2022)。因此，本文进一步以在险价值、边际期望损失两种金融风险测度指标构建回归模型，深入剖析银行业风险偏好对金融风险的驱动影响，结果展示于表4。

表4 银行风险偏好对金融风险的影响

	模型Ⅰ	模型Ⅱ	模型Ⅲ	模型Ⅳ	模型Ⅴ	模型Ⅵ	模型Ⅶ	模型Ⅷ
	MES ^{***}	MES ^{***}	MES ^{***}	MES ^{***}	VaR ^{***}	VaR ^{***}	VaR ^{***}	VaR ^{***}
单位资产风险偏好	0.031 [*] [0.085]	0.040 ^{**} [0.022]			0.021 [0.228]	0.026 ^{**} [0.028]		
规模加权风险偏好			0.032 ^{**} [0.016]	0.026 [0.170]			0.030 ^{***} [0.006]	0.020 ^{**} [0.050]
MES	0.636 ^{***} [0.000]	0.581 ^{***} [0.000]	0.636 ^{***} [0.000]	0.583 ^{***} [0.000]				
VaR					0.453 ^{***} [0.000]	0.596 ^{***} [0.000]	0.452 ^{***} [0.000]	0.598 ^{***} [0.000]
账面市值比		-0.628 ^{**} [0.019]		-0.631 ^{**} [0.020]		-0.564 ^{**} [0.033]		-0.565 ^{**} [0.033]
银行规模		0.016 [0.179]		0.017 [0.159]		0.009 [0.301]		0.009 [0.275]
M2增长率		-0.068 ^{***} [0.000]		-0.070 ^{***} [0.000]		-0.026 [0.103]		-0.028 [*] [0.093]
期限利差		0.083 ^{***} [0.000]		0.083 ^{***} [0.000]		0.029 ^{***} [0.000]		0.029 ^{***} [0.000]
净股本扩张		-0.226 ^{***} [0.000]		-0.223 ^{***} [0.000]		-0.113 ^{***} [0.000]		-0.111 ^{***} [0.000]
控制变量	否	是	否	是	否	是	否	是
个体固定效应	是	是	是	是	是	是	是	是
观测值	2709	2628	2709	2628	2709	2628	2709	2628
adj. R ²	0.427	0.493	0.427	0.492	0.379	0.453	0.379	0.453

注：(1)上表中的基准回归方程为： $SysRisk_{i,t+1} = \alpha + \beta RiskTaking_{i,t} + \theta SysRisk_{i,t} + \gamma Controls_{i,t} + \delta + \epsilon_{i,t}$ ，被解释变量为金融风险指标，其中，模型Ⅰ~模型Ⅳ为边际期望损失(MES)，模型Ⅴ~模型Ⅷ为在险价值(VaR)，主要解释变量为银行风险偏好；(2)除账面市值比、银行规模、M2增长率、期限利差、净股本扩张外，其他控制变量包括股息发放率、总资产周转率、营业利润率、投资性房地产占比以及有形资产占比，后续表5~表7与此相同，不再赘述；(3)*、**、***分别代表系数在90%、95%、99%的置信水平下显著，方括号内为p值，依据稳健标准误计算，后续表5~表7相同，不再赘述。

由表 4 的模型 I 可知,银行业单位资产风险偏好对边际期望损失存在显著的正向影响。这意味着,银行业风险偏好的提升,往往会导致潜在金融风险的积聚。与此同时,模型 II 中加入其他控制变量后的结果保持一致,其中值得注意的是,在控制变量中 M2 增长率以及净股本扩张的系数显著为负,而期限利差则对风险产生了正向驱动。这表明,在货币供应量增速放缓、金融市场融资金额较低或是长期不确定性相对较高的时期,系统性风险水平往往更高。与此同时,我们在表 4 的模型 III 中,将主要解释变量替换为规模加权的风险偏好,结论同样一致稳健。与此相类似的,模型 VI~模型 VIII 同样显示,风险偏好指标对在险价值的影响系数均显著为正,这也再次佐证了,我国银行业风险偏好的上升,将明显加速金融风险积聚^⑧。

在表 5 中,我们进一步探究了资本充足率等传统监管指标对金融风险的解释力度。表 5 表明,杠杆倍数与资本充足率、一级资本充足率以及核心一级资本充足率等巴塞尔协议 III 中的传统监管指标,对银行业金融风险的影响均不显著^⑨。究其原因,尽管监管机构对银行业杠杆率与资本充足率等指标进行了严格监管,但为了实现利润最大化,部分银行可能通过监管套利等方式规避传统监管要求(蔡等,2020;阿拉赫拉哈等,2018),从而使得传统指标难以有效反映银行的潜在风险水平。

与此同时,为了考察银行业风险偏好指标是否提供了额外的增量信息,我们在回归中进一步控制了传统监管指标,探究风险偏好指标对金融风险的影响。表 6 中模型 I~模型 III、模型 VII~模型 IX、以及模型 XI~模型 XII 的结果均显示,在控制杠杆倍数以及资本充足率指标后,银行业风险偏好对在险价值与边际期望损失的影响仍显著为正^⑩。这就意味着,与传统监管指标相比,银行业风险偏好提供了额外的增量信息,若将其纳入金融风险监测模型,或有助于我们进一步完善前瞻性的系统性金融风险预测体系。

进一步地,本文探究了我国银行风险偏好对金融风险的长期影响,并在图 4 中展示了未来 12 个月的回归分析结果。图 4(a) 显示,在冲击初期,银行风险偏好的提升对边际期望损失产生了显著的正向驱动,且该冲击的持续时间长达 8 个月。这就意味着,商业银行风险偏好的提升,可能导致其资产质量下降、不良贷款率增加,致使银行流动性风险、信用风险持续积聚,加剧金融风险隐患。图 4(b) 中进一步展示了控制杠杆与资本充足率的分析结论,分析结果表明,在控制传统金融

表 5 传统银行监管指标对金融风险的影响


	模型 I	模型 II	模型 III	模型 IV	模型 V	模型 VI	模型 VII	模型 VIII
	MES st	VaR st	MES st	VaR st	MES st	VaR st	MES st	VaR st
杠杆倍数	-0.019 [0.371]	-0.012 [0.503]						
资本充足率			0.006 [0.785]	-0.020 [0.222]				
一级资本充足率					0.042 [0.142]	0.026 [0.211]		
核心一级资本充足率							0.050 [0.133]	0.026 [0.225]
MES	0.577*** [0.000]		0.577*** [0.000]		0.575*** [0.000]		0.574*** [0.000]	
VaR		0.602*** [0.000]		0.601*** [0.000]		0.599*** [0.000]		0.599*** [0.000]
其他控制变量	是	是	是	是	是	是	是	是
个体固定效应	是	是	是	是	是	是	是	是
观测值	3002	3002	2890	2890	2884	2884	2890	2890
adj.R ²	0.498	0.449	0.491	0.441	0.491	0.440	0.492	0.441

注:上表中的基准回归方程为: $SysRisk_{i,t+1} = \alpha + \beta X_{i,t} + \theta SysRisk_{i,t} + \gamma Controls_{i,t} + \delta + \epsilon_{i,t}$, 被解释变量为金融风险指标, 主要解释变量 $X_{i,t}$ 分别为银行杠杆倍数与资本充足率等传统监管指标。

表 6 剔除传统银行监管指标影响的进一步分析

	模型 I	模型 II	模型 III	模型 IV	模型 V	模型 VI	模型 VII	模型 VIII	模型 IX	模型 X	模型 XI	模型 XII
	MES st	MES st	MES st	MES st	MES st	MES st	VaR st	VaR st	VaR st	VaR st	VaR st	VaR st
单位资产风险偏好	0.044*** [0.025]	0.050*** [0.014]	0.050*** [0.014]				0.024* [0.073]	0.032** [0.025]	0.031** [0.027]			
规模加权风险偏好				0.027 [0.184]	0.031 [0.129]	0.030 [0.139]				0.017 [0.104]	0.023** [0.038]	0.022** [0.045]
杠杆倍数	-0.017 [0.467]	0.027 [0.396]	0.015 [0.550]	-0.018 [0.471]	0.021 [0.525]	0.012 [0.661]	-0.028 [0.194]	0.017 [0.477]	0.007 [0.732]	-0.028 [0.204]	0.014 [0.574]	0.005 [0.804]
资本充足率	-0.003 [0.904]			-0.009 [0.737]			-0.038* [0.100]			-0.041* [0.066]		
一级资本充足率		0.060 [0.129]			0.049 [0.194]			0.035 [0.235]			0.029 [0.308]	
核心一级资本充足率			0.055 [0.123]			0.045 [0.181]			0.027 [0.301]			0.022 [0.392]
MES	0.581*** [0.000]	0.578*** [0.000]	0.578*** [0.000]	0.582*** [0.000]	0.581*** [0.000]	0.580*** [0.000]						
VaR							0.592*** [0.000]	0.592*** [0.000]	0.593*** [0.000]	0.593*** [0.000]	0.594*** [0.000]	0.594*** [0.000]
其他控制变量	是	是	是	是	是	是	是	是	是	是	是	是
个体固定效应	是	是	是	是	是	是	是	是	是	是	是	是
观测值	2516	2510	2516	2516	2510	2516	2516	2510	2516	2516	2510	2516
adj.R ²	0.484	0.484	0.485	0.483	0.483	0.484	0.445	0.444	0.444	0.444	0.443	0.443

注:上表中的基准回归方程为: $SysRisk_{i,t+1} = \alpha + \beta_1 RiskTaking_{i,t} + \beta_2 X_{i,t} + \theta SysRisk_{i,t} + \gamma Controls_{i,t} + \delta + \epsilon_{i,t}$, 被解释变量为金融风险指标, 主要解释变量包括银行风险偏好 $RiskTaking_{i,t}$ 、银行杠杆与资本充足率等传统监管指标 $X_{i,t}$ 。



注：(1)图中黑色实线表示回归系数，浅灰色区域表示90%置信区间，深灰色区域表示正负一倍标准差的范围。(2)图(a)中主要解释变量仅包含单位资产风险偏好，图(b)中进一步控制银行杠杆以及资本充足率。(3)将风险指标替换为在险价值，资本充足率指标替换为核心资本充足率、一级核心资本充足率，均不影响结论的稳健性与一致性，结果备索。

监管指标后，银行风险偏好对系统性金融风险仍存在显著的长期影响，进一步佐证了前文的分析结论^①。

此外，整体市场环境下行时，较高的风险偏好容易引发资本市场震荡，甚至诱发系统性金融风险。因此，我们结合马查多和席尔瓦(2019)提出的面板数据分位数回归方法，考察不同分位数水平下，风险偏好与金融风险之间的关联。由表7可知，随着分位数的提升，风险偏好对金融风险的回归系数大幅增加。特别地，表7的Panel A与Panel B一致显示，在模型VI~IX中，风险偏好系数在60%以上分位数的区间内均显著为正，且该系数同样随着分位数的提升而明显增加(0.039→0.096、0.025→0.085)。

这就意味着，风险偏好在一定程度上成为了极端金融风险事件的“催化剂”。因此，监管机构应准确测度、实时追踪重点机构的风险偏好变动，构建风险防控预案，并在国际金融市场持续震荡等高风险时期，适时适度提高监管要求。同时，金融机构也应定期评估、更新风险管理策略，提升对高风险行为的内部控制，从而实现风险的“早识别、早预警、早暴露、早处置”，维护经济金融系统的平稳运行。

(三)金融风险的预测——基于前沿机器学习方法

在前文分析中，本文结合了回归分析等方法，考察风险偏好指标对金融风险的驱动影响，就样本内的数据拟合情况展开深入分析。然而，对于传统回归分析模型而言，样本内拟合与样本外的预测结果存在明显的差异，且此类方法往往存在过拟合的缺陷，可能忽略了金融序列中的非线性性质(比安奇等，2021；古莱·库隆布等，2022)。这就意味着，样本内拟合效果较好的传统模型，未必能对金融风险展开有效预测。随着该领域研究的不断深入，前沿的机器学习方法有效地克服了上述缺陷，能够更具前瞻性地对金融风险展开预测。因此，

表7 银行业风险偏好对金融风险的分位数回归分析

Panel A: 被解释变量为边际期望损失									
	模型 I	模型 II	模型 III	模型 IV	模型 V	模型 VI	模型 VII	模型 VIII	模型 IX
	$MES^{10, t+1}$	$MES^{20, t+1}$	$MES^{30, t+1}$	$MES^{40, t+1}$	$MES^{50, t+1}$	$MES^{60, t+1}$	$MES^{70, t+1}$	$MES^{80, t+1}$	$MES^{90, t+1}$
风险偏好	0.001 [0.943]	0.011 [0.447]	0.018 [0.183]	0.023* [0.069]	0.030** [0.024]	0.039** [0.013]	0.050** [0.013]	0.067** [0.020]	0.096** [0.032]
MES	0.536*** [0.000]	0.547*** [0.000]	0.555*** [0.000]	0.562*** [0.000]	0.570*** [0.000]	0.579*** [0.000]	0.593*** [0.000]	0.613*** [0.000]	0.647*** [0.000]
其他控制变量	是	是	是	是	是	是	是	是	是
个体固定效应	是	是	是	是	是	是	是	是	是
观测值	2628	2628	2628	2628	2628	2628	2628	2628	2628
Panel B: 被解释变量为在险价值									
	模型 I	模型 II	模型 III	模型 IV	模型 V	模型 VI	模型 VII	模型 VIII	模型 IX
	$VarR^{10, t+1}$	$VarR^{20, t+1}$	$VarR^{30, t+1}$	$VarR^{40, t+1}$	$VarR^{50, t+1}$	$VarR^{60, t+1}$	$VarR^{70, t+1}$	$VarR^{80, t+1}$	$VarR^{90, t+1}$
风险偏好	-0.018 [0.199]	-0.008 [0.496]	-0.000 [0.996]	0.007 [0.472]	0.014 [0.155]	0.025** [0.034]	0.037** [0.014]	0.055*** [0.009]	0.085*** [0.008]
VarR	0.474*** [0.000]	0.503*** [0.000]	0.524*** [0.000]	0.543*** [0.000]	0.564*** [0.000]	0.594*** [0.000]	0.627*** [0.000]	0.679*** [0.000]	0.761*** [0.000]
其他控制变量	是	是	是	是	是	是	是	是	是
个体固定效应	是	是	是	是	是	是	是	是	是
观测值	2628	2628	2628	2628	2628	2628	2628	2628	2628

注：(1)表中被解释变量的上标表示其对应的分位数水平与期数，例如 $MES^{10, t+1}$ 为10%分位数下 $t+1$ 期的边际期望损失；(2)表中仅展示了以单位资产风险偏好作为主要解释变量的分析结果，基于规模加权风险偏好的分析结果备索。

本文结合银行业风险偏好指标,采用前沿的机器学习方法预测我国银行业的金融风险,并据此选择最优的金融风险预测模型,深入对比分析各变量的预测效果。


具体而言,本文分别采用最小二乘回归、偏最小二乘回归、主成分回归、LASSO、弹性网络5种传统线性模型,以及梯度提升回归树与随机森林两类前沿的机器学习方法,对系统性风险的预测展开建模分析^②。依据该领域研究惯例,我们选取2010年1月~2016年12月的数据作为训练集,并在训练集中划分20%的样本作为测试集,同时将2017年1月~2020年12月的样本作为验证集,逐年递归更新预测模型。

由图5(a)基于边际期望损失的分析结果可知,在7种预测模型中,梯度提升回归树、随机森林两类机器学习方法的样本外拟合优度最高,分别达到了39.06%与41.12%,泛化能力较强。与此相对应的,其他5类正则化预测模型的样本外 R^2 较小,预测效力相对较低,其中最小二乘估计的拟合优度更是仅为11.15%。这是因为,传统回归模型在应用时需满足严格的前提条件(例如,因变量与被解释变量需要满足线性关系,且服从正态分布、同方差等),但上述假设在现实中往往无法严格成立。因此,传统模型易出现过拟合等问题,难以从高维数据中提取真正有效的预测信息,也无法有效捕捉金融序列中的非对称、非线性特征,泛化能力相对较弱,这也与莱波尔德等(2022)等人的研究相一致。而与此相对应的,机器学习模型则具有数据驱动的特点,模型设定相对灵活,能够更好地估计变量间复杂的相互关联、识别潜在的非线性关系。


此外,我们同样采用在险价值指标进行稳健性检验。图5(b)中结果表明,与(a)中基于边际期望损失的结论相一致,梯度提升回归树、随机森林的样本外预测能力均高于传统模型,样本外 R^2 分别达到了50.93%与53.97%。这再次证明,前沿的机器学习方法泛化能力相对较强,且对不同指标预测能力较为稳健。

在不同经济金融环境下,良好的金融风险预测模型应当在时间维度上具有稳健的预测能力。因此,遵循普罗卡斯基和尹(2022)的建议,我们结合均方预测误差的累积差值^③与样本外 R^2 ,深入考察各预测方法在时间维度上预测能力的波动性,图6分别展示了样本外 R^2 以及均方预测误差的累积差值的变化趋势,其中,图6(a)、(b)显示,对于主成分回归等传统方法而言,样本外 R^2 仅在部分区间内位于零线上方,均方预测误差的累积差值更是在2018年间出现了明显的下跌态势。这就表明,此类模型的预测能力较为受限,总体预测效力的稳定程度相对较低。与此相对应的,图6(c)、(d)的结果表明,总体而言,在梯度提升回归树以及随机森林模型中,均方预测误差的累积差值均大于传统模型,且呈持续上升趋势,这就意味着机器学习模型的预测能力高于其他模型,平均预测性能更强,且在不同时间段内均有着较好的表现。

前文分析表明,在我国银行系统中各金融机构风险偏好的提升会显著加剧金融风险积聚。因此,在此基础上,我们进一步对比风险偏好指标、资本充足率指标以及杠杆倍数在金融风险预测中的作



(a) 边际期望损失的样本外预测



(b) 在险价值的样本外预测

图5 7种建模方法预测能力的对比分析

注:(1)样本外拟合优度越高意味着模型的预测能力越强。(2)图中颜色从深到浅的柱形分别表示最小二乘回归、偏最小二乘回归、主成分回归、LASSO、弹性网络、梯度提升回归树以及随机森林的样本外拟合优度。

用。其中,图7(a)、(b)一致表明,较之资本充足率(杠杆倍数),在各模型均以银行风险偏好指标为核心解释变量时,其样本外 R^2 均出现了明显提升。究其原因,戈顿和奥多内斯(2020)研究发现,“好的繁荣”与“虚假繁荣”都将导致信贷扩张。其中,“好的繁荣”即指由贷款需求增长驱动的信贷扩张,而“虚假繁荣”中信贷扩张则主要由银行资金成本下降引发。因此,若仅采用杠杆倍数与资本充足率指标,则难以有效区分“好的繁荣”与“虚假繁荣”,无法准确识别金融机构信贷扩张的根本原因,增加了金融风险的防控难度。而风险偏好的增加




图6 不同时间段内预测能力的对比分析

注:(1)图中灰色实线表示分别以样本中每一年1~6月、7~12月为子样本计算的样本外预测,而黑色虚线则表示均方预测误差的累积差值。(2)样本外预测 R^2 如左轴所示,均方预测误差的累积差值如右轴所示。(3)上图展示了以边际期望损失作为因变量的分析结果,基于在险价值指标的分析结果备案。




图7 银行业风险偏好指标与传统指标样本外预测性能的对比

注:(1)图中黑色柱形表示,包含银行业风险偏好的预测模型的样本外 R^2 ,图(a)中灰色柱形表示包含银行业资本充足率的预测模型的样本外 R^2 ,图(b)中灰色柱形表示包含杠杆倍数的预测模型的样本外 R^2 。(2)上图展示了以边际期望损失作为因变量的分析结果,在险价值的预测结果备案。

则主要是由于银行资金成本的下降或是信贷约束的放松,往往意味着信贷的“虚假繁荣”,较好地克服了传统指标的缺陷,显著提升了预测模型的样本外拟合优度,有助于我们更为准确、及时地对金融风险进行有效预警^①。

进一步地,我们结合DM检验统计量,探究各模型预测能力的差异。首先,我们在表8的Panel A中对比分析了不同模型的预测能力,可以发现,与前文的分析结论一致,对于最小二乘回归、偏最小二乘回归等5类传统模型而言,其DM检验统计量均为正,且在1%的显著性水平上拒绝了“该模型的预测能力等于随机森林(梯度提升回归)模型”的原假设,其预测能力显著低于机器学习模型。与此同时,对在险价值展开预测时,基于随机森林的检验值显著为负,这就意味着,较之梯度提升回归模型,随机森林模型对在险价值的预测效力更高。此外,表8的Panel B显示,多数情况下,银行业风险偏好比资本充足率、杠杆倍数等传统指标更能有效预测银行业金融风险,即风险偏好指标提供了额外的增量信息,再次印证了前文的分析结论。

最新研究指出,机器学习模型能够更有效地刻画数据样本中的非线性关联,且在长期预测中往往有着更好的表现(古莱·库隆布等,2022)。因此,我们在纳入风险偏好指标的基础上,采用机器学习方法,预测未来1~6个月的风险水平,并在表9中展示。表9中Panel A与Panel B一致显示,在大多数时期,梯度提升回归树、随机森林模型的样本外预测 R^2 均为正,且高于其他模型,表明其能够对未来银行业的金融风险展开稳定、有效的预测。这意味着,我国在建立系统性金融风险预测体系时,应综合考量金融机构风险偏好等重要指标,同时结合前沿的机器学习方法,构建金融风险的前瞻性预测模型,从而在重点领域金融风险积聚初期实现“精准拆弹”,防患于未然。

银行业风险偏好的上升是金融风险积聚的重要原因。例如,在2002~2006年间,受美联储连续多次降息以及“低首付”“零首付”购房方式影响,美国各金融机构大量向信用评级较低、偿还能力不足的借款人提供次级贷款,风险偏好始终居于高位,致使金融风险隐患持续加剧,并最终诱发2007年美国次贷危机乃至2008年国

表8 各模型预测能力的对比分析

Panel A: 基于不同模型							
因变量	预测模型						
	最小二乘回归	偏最小二乘回归	主成分回归	LASSO	弹性网络	梯度提升回归树	随机森林
MES	7.273*** [0.000]	6.034*** [0.000]	4.666*** [0.000]	4.107*** [0.000]	4.577*** [0.000]	1.613 [0.109]	--
VaR	5.698*** [0.000]	5.084*** [0.000]	5.539*** [0.000]	5.259*** [0.000]	5.505*** [0.000]	2.433** [0.021]	--
MES	7.078*** [0.000]	5.280*** [0.000]	3.538*** [0.001]	3.197*** [0.002]	3.727*** [0.000]	--	-1.613 [0.109]
VaR	5.184*** [0.000]	3.880*** [0.000]	3.819*** [0.000]	3.257*** [0.002]	3.526*** [0.001]	--	-2.433** [0.021]

Panel B: 基于不同指标							
因变量	对比指标	预测模型					
		最小二乘回归	偏最小二乘回归	主成分回归	LASSO	弹性网络	梯度提升回归树
MES	风险偏好 vs 资本充足率	1.078 [0.223]	4.885*** [0.000]	1.076 [0.224]	6.364*** [0.000]	6.798*** [0.000]	2.812*** [0.008]
MES	风险偏好 vs 杠杆倍数	-1.401 [0.149]	3.459*** [0.001]	1.345 [0.161]	6.357*** [0.000]	7.180*** [0.000]	4.079*** [0.000]
VaR	风险偏好 vs 资本充足率	-0.062 [0.398]	0.375 [0.372]	-1.15 [0.204]	2.934*** [0.005]	2.726*** [0.010]	-3.885*** [0.000]
VaR	风险偏好 vs 杠杆倍数	-0.499 [0.352]	-1.271 [0.178]	-2.095** [0.044]	5.758*** [0.000]	4.353*** [0.000]	-1.171 [0.201]

注:(1)Panel A对比不同方法的预测能力,第1~2行的原假设为“该模型的预测能力等于随机森林模型”,第3~4行的原假设为“该模型的预测能力等于梯度提升回归模型”。检验统计量显著为正意味着机器学习模型(随机森林模型、梯度提升回归模型)的预测能力更强。(2)Panel B对比不同指标的预测能力,原假设为“资本充足率(杠杆倍数)指标的预测能力等于银行业风险偏好指标”,检验统计量显著为正意味着银行业风险偏好指标的预测能力更强。

表9 不同期限下各预测模型预测能力的对比分析

Panel A: 预测边际期望损失						
	一个月	两个月	三个月	四个月	五个月	六个月
最小二乘回归	11.150%	-93.309%	-98.100%	-98.098%	-65.095%	-83.373%
偏最小二乘回归	27.364%	-20.474%	-36.395%	20.161%	22.922%	8.698%
主成分回归	32.800%	-49.649%	-76.164%	-83.699%	-27.777%	-27.871%
LASSO	33.715%	-28.508%	-50.064%	-49.656%	-10.539%	-2.622%
弹性网络	32.718%	-29.521%	-52.772%	-51.066%	-12.276%	-4.397%
梯度提升回归树	39.056%	19.541%	-6.314%	12.192%	12.535%	20.565%
随机森林	41.121%	20.074%	17.108%	21.133%	23.695%	19.237%

Panel B: 预测在险价值						
	一个月	两个月	三个月	四个月	五个月	六个月
最小二乘回归	17.522%	-73.427%	-32.861%	-71.770%	-63.285%	-104.826%
偏最小二乘回归	40.166%	-3.657%	8.251%	31.640%	7.974%	11.086%
主成分回归	44.265%	-9.000%	-20.630%	-37.474%	-12.270%	-14.243%
LASSO	46.135%	1.011%	-2.924%	-19.008%	-3.716%	-3.547%
弹性网络	45.452%	0.379%	-4.758%	-20.895%	-4.217%	-4.142%
梯度提升回归树	50.930%	19.307%	17.917%	17.689%	18.607%	24.385%
随机森林	53.967%	29.068%	24.379%	30.454%	29.355%	25.756%

注:上表展示各模型对未来1~6个月金融风险预测的样本外 R^2 。

四、结论与启示

银行业风险偏好的上升是金融风险积聚的重要原因。例如,在2002~2006年间,受美联储连续多次降息以及“低首付”“零首付”购房方式影响,美国各金融机构大量向信用评级较低、偿还能力不足的借款人提供次级贷款,风险偏好始终居于高位,致使金融风险隐患持续加剧,并最终诱发2007年美国次贷危机乃至2008年国

际金融危机。与此同时,近年来,我国部分高风险偏好银行的风险持续积聚,并由此引发“暴雷”事件,但迄今为止,现有国内文献仍较少从银行风险偏好的角度展开深入研究。有鉴于此,本文创新性地基于银行业风险偏好这一研究视角,采用前沿的机器学习方法对我国银行业金融风险展开前瞻性预测。

首先,本文测算了我国银行业风险偏好在2009~2020年间的演变趋势,发现银行风险偏好在金融风险事件爆发前会出现明显攀升,能较好地对风险事件展开提前预测。此外,被依规接管、处置的恒丰银行、包商银行的风险偏好均在“暴雷”前迅速上扬,再次凸显了该指标在风险预测时的前瞻性。究其原因,银行风险偏好的提升,将诱使其持有更多的高风险金融资产、从事不确定性更强的业务,并以相对宽松的标准发放信贷,加剧金融风险隐患。与此同时,各银行的风险偏好存在明显的异质性,其中,城商行、农村金融机构的单位资产风险偏好往往更大,而大型商业银行与股份制商业银行的规模加权风险偏好指标则相对更高。

其次,银行业风险偏好对边际期望损失、在险价值指标均存在显著的正向影响,而杠杆倍数与资本充足率、一级资本充足率以及核心一级资本充足率等巴塞尔协议Ⅲ中的传统银行监管指标,对金融风险的影响则均不显著。究其原因,为了实现利润最大化,银行可能通过监管套利等方式规避传统监管要求,使得传统指标难以准确刻画银行的潜在风险水平。而风险偏好指标则提供了额外的增量信息,在风险预测方面具有重要的应用价值。并且,值得注意的是,风险偏好对金融风险的影响将随着分位数水平的提高明显增加,即在整体市场环境下行时,高风险偏好将进一步加剧金融市场震荡,在一定程度上成为金融风险的“催化剂”。

再者,本文结合前沿的机器学习方法,预测我国银行业的金融风险,并就其与传统模型的预测效力展开深入的对比分析。我们发现,随机森林、梯度提升回归树等机器学习方法的预测能力更强,基于边际期望损失与在险价值指标的样本外预测 R^2 分别达到了39.06%与41.12%、50.93%与53.97%,远高于最小二乘回归、LASSO、弹性网络等模型,具有较强的泛化能力,有效克服了传统方法存在的过拟合等问题。与此同时,此类机器学习模型的预测能力在不同时间段内均有着较好的表现,预测效力更为稳定、有效。

最后,本文的分析结论显示,风险偏好指标是金融风险前瞻性预测的重要指标,且较之采用传统银行风险监管指标构建的预测模型,基于风险偏好指标构建的随机森林、梯度提升回归树模型的样本外拟合优度均明显提升。

基于以上富有启发意义的研究结论,本文得到以下3点启示。

第一,内外并举构建并完善以资本充足率为核心、风险偏好作为重要补充的银行业风险防范体系。本文对恒丰银行、包商银行案例分析结果显示,两家金融机构在“暴雷”前的风险偏好指标均迅速攀升。与此同时,回归分析发现,在控制杠杆倍数以及资本充足率指标后,银行业风险偏好对在险价值与边际期望损失的影响仍显著为正。这就意味着,银行风险偏好已成为金融风险的前瞻性指标。因此,尽管据《中国金融稳定报告(2023)》显示,中国人民银行已建立了涵盖扩张性风险、同业风险、流动性风险、信用风险、综合风险5个方面的风险监测体系,对银行风险展开了较好的风险预警工作。但在国际政治经济局势持续动荡、我国经济金融持续承压的背景下,我们必须进一步加强风险防控体系建设,持续提升风险预测工作的准确性与有效性。例如,监管机构可考虑将风险偏好这一指标作为重要补充,对各金融机构风险展开实时监控,同时搭建预警系统,分层分级设立预警标准,依据风险偏好等指标对预警线的偏离程度,适时、适度采取预防措施与调控政策,从而更为及时地缓释系统性风险。此外,各金融机构也应进一步加强风险内控管理,细化并提高自主风控要求,事先划定相应企业信用等级、实现贷款投放的精准画像,在加强银行业对民营企业、小微企业、初创企业金融服务支持的同时,切实压降存量风险、严控增量风险,推动形成“双循环”的新发展格局。

第二,基于不同风险偏好、不同市场条件实施分类差异化管理,合理分配、统筹监管资源与处置资源。本文研究结论表明,大型商业银行与股份制商业银行加权风险偏好普遍较高;而城商行、农村金融机构的单位资产风险偏好则相对更高,且该类型金融机构数目较多、分布也相对分散,风险偏好存在明显异质性。这就意味着,监管机构应当加快健全金融机构风险分层分类管理系统,结合经济发展实际条件,有效识别金融系统中的风险薄弱环节,依据不同风险偏好对各机构进行动态风险评级,审时度势强化监管要求,实施分类差异化管

理,重点防范规模加权风险偏好、单位资产风险偏好较高机构的潜在风险隐患。此外,还应合理分配监管资源,确保监管机构能够有效覆盖所有金融机构。统筹分配人力资源、技术支持、监管工具等方面的资源,更好地应对不同机构的差异化监管需求。与此同时,本文还发现,随着分位数的提升,风险偏好对金融风险的回归系数大幅增加。因此,在市场剧烈震荡时期,各监管机构更应及时、适度提高审慎监管要求,对风险偏好过高的金融机构采用约谈等针对性措施,以缓释、化解系统性金融风险。

第三,结合前沿机器学习方法优化金融风险预警体系,提高风险防控主动性、前瞻性与有效性。传统的风险预测模型依赖于固定的参数和假设,大幅降低了其在复杂金融环境中的适用性;而与此相对应的,机器学习方法能够有效克服传统风险预测模型的缺陷,最大程度地捕捉增量信息、避免信息损失,从而有助于我们对金融机构展开稳定、有效的风险预测。同时,本文研究结果也表明,随机森林、梯度提升回归树的样本外预测 R^2 也高于最小二乘回归、LASSO、弹性网络等传统模型,预测效力相对更高。因此,监管机构应当在金融风险预测体系中,进一步纳入随机森林、梯度提升回归树等前沿的机器学习方法,加强对系统重要性银行的动态风险的主动预警与事前干预,优化、完善金融风险防范与预警体系建设。同时,政府也应持续推进金融科技监管大数据平台建设,推动各金融机构信息互联互通,通过统一存储、管理跨机构、跨业务数据等方式,实现对企业工商变更、监管处罚、司法诉讼等信息以及各金融创新产品的全面覆盖。此外,还可利用机器学习预测模型扩大搜寻范围、提高风险排查效率,对银行业过度从事高风险业务的行为进行及时纠偏,实现金融风险的“早发现、早介入、早处置”,提高系统性风险防控的主动性、前瞻性与有效性^⑤。

(作者单位:杨子晖,上海财经大学金融学院、上海财经大学滴水湖高级金融学院;李东承,华南理工大学经济与金融学院;陈雨恬,上海财经大学金融学院)

注释

①国内学者也从不同的角度对金融风险展开了很好的分析,其中的代表性研究包括陈海强等(2019)、荆中博等(2022)、李政等(2019)、梁琪和常姝雅(2022)、刘晓星等(2021)、吴卫星等(2020)、杨子晖和陈雨恬(2022)、杨子晖和李东承(2018)以及郑挺国等(2021)。

②文中“未加权风险偏好”与“未加权的银行风险偏好”均代表“单位资产风险偏好”,“加权风险偏好”与“规模加权的风险偏好”则为“规模加权风险偏好”。

③梯度提升回归树模型有深度 L 、树的数量 B 以及学习率 ν 这3个超参数。

④随机森林模型有深度 L 、树的数量 B 以及构建简单树的特征数量 f 这3个超参数。

⑤本文选用的具体指标详见《管理世界》网络发行版附录一。

⑥技术进步与生产力的提升能够增加企业和经济体的生产效率和盈利能力,使企业倾向于使用债务融资扩大业务规模、促进投资增长,从而导致信贷需求增加,推动信贷扩张与杠杆水平的提升。

⑦中国人民银行发布的《中国金融稳定报告(2020)》中提及“对包商银行、恒丰银行、锦州银行等分类施策,有序化解了重大风险,强化市场纪律。”

⑧为了保障经济的高质量发展,国有大型银行在国家面临经济增长压力时,可能会出现明显的信贷扩张行为,从而导致结论出现偏差。因此,我们在《管理世界》网络发行版附录二中进一步展开稳健性分析,结果保持稳健。

⑨《巴塞尔协议Ⅲ》与我国《商业银行资本管理办法》均将资本充足率与杠杆率列为资本监管指标。但银行杠杆率的数据缺失较多,因此,遵循该领域的一贯做法(阿德里安、申,2010,2014;王倩、赵铮,2018;杨子晖、李东承,2021),本文以杠杆倍数刻画银行杠杆水平。

⑩《管理世界》网络发行版附录三中进一步提供了分别控制杠杆倍数以及资本充足率指标的结果,结论同样保持稳健。

⑪《管理世界》网络发行版附录四中结合面板格兰杰因果检验方法,验证了银行业风险偏好与金融风险之间的关联关系,结论稳健。

⑫为了减轻异常值对模型拟合的影响,本文在最小二乘回归、偏最小二乘回归、LASSO、弹性网络以及梯度提升回归树模型中均使用Huber形式的目标函数进行估计。遵循该领域文献的研究惯例(顾等,2020;莱波尔德等,2022),本文将Huber函数的参数 M 设置为1.35。此外,LASSO方法与弹性网络方法的介绍详见《管理世界》网络发行版附录五。

⑬均方预测误差累积差值的具体计算公式详见普罗卡斯基和尹(2022),该指标越大意味着预测误差越小、预测能力越强。

⑭《管理世界》网络发行版附录六中进一步分析了变量重要性,进一步验证了风险偏好指标在银行风险预测中的重要作用。

⑮中外文人名(机构名)对照:法塔斯(Fatás);萨默斯(Summers);巴伦(Baron);杜阿尔特(Duarte);艾森巴赫(Eisenbach);迈恩(Mian);苏非(Sufi);舒拉里克(Schularick);泰勒(Taylor);科英布拉(Coimbra);布朗利斯(Brownlees);恩格尔(Engle);德尔阿里恰(Dell'Ariceia);里克特(Richter);蔡(Choi);雷伊(Rey);荆(Jing);霍多罗夫-赖克(Chodorow-Reich);法拉托(Falato);阿布-埃尔-苏德(Abou-El-Sood);高(Gao);陈(Chen);李(Li);莱波尔德(Leippold);顾(Gu);戈顿(Gorton);奥多内斯(Ordóñez);巴哈特(Bhagat);穆鲁齐杜-丹姆察(Mourouzdou-Damtsa);里格(Rieger);布兰道-马克斯(Brandao-Marques);哈根多夫(Hagendorff);布罗兹(Brož);科琴达

重大选题征文

(Kočenda);阿拉赫拉哈(Allahrakha);马查多(Machado);席尔瓦(Silva);比安奇(Bianchi);古莱·库隆布(Goulet Coulombe);普罗卡斯基(Procasky);尹(Yin);勒鲁(Leroux);阿德里安(Adrian);申(Shin)。

参考文献

- (1)陈海强、方颖、王方舟:《融资融券制度对尾部系统风险的非对称影响——基于A股市场极值相关性的研究》,《管理科学学报》,2019年第5期。
- (2)荆中博、李雪萌、方意:《跨境资本周期性波动对中国银行部门的风险溢出机制分析》,《世界经济》,2022年第1期。
- (3)李政、刘洪、梁琪:《基于经济金融关联网络的中国系统性风险防范研究》,《统计研究》,2019年第2期。
- (4)梁琪、常殊雅:《全球股票市场系统性风险的预警与防范——基于高低波动风险溢出网络的分析》,《国际金融研究》,2022年第9期。
- (5)刘晓星、张旭、李守伟:《中国宏观经济韧性测度——基于系统性风险的视角》,《中国社会科学》,2021年第1期。
- (6)王倩、赵铮:《同业融资视角下的商业银行杠杆顺周期性》,《金融研究》,2018年第10期。
- (7)吴卫星、刘细宪、钟腾:《政府和社会资本合作对企业债务期限结构的影响——来自中国上市公司的微观证据》,《系统工程理论与实践》,2020年第6期。
- (8)杨子晖、陈雨恬:《财政金融统一框架下的金融风险测度与分析——基于非线性网络关联的方法》,《中国社会科学》,2022年第11期。
- (9)杨子晖、李东承:《我国银行系统性金融风险研究——基于“去一法”的应用分析》,《经济研究》,2018年第8期。
- (10)杨子晖、李东承:《系统性风险指标是否具有前瞻性的预测能力?》,《经济学(季刊)》,2021年第2期。
- (11)郑挺国、龚基金、宋涛:《中国城市房价泡沫测度及其时变传染效应研究》,《世界经济》,2021年第4期。
- (12)Abou-El-Sood, H., 2016, “Are Regulatory Capital Adequacy Ratios Good Indicators of Bank Failure? Evidence From US Banks”, *International Review of Financial Analysis*, Vol.48, pp.292~302.
- (13)Adrian, T. and Shin, H. S., 2010, “Liquidity and Leverage”, *Journal of Financial Intermediation*, Vol.19, No.3, pp.418~437.
- (14)Adrian, T. and Shin, H. S., 2014, “Procyclical Leverage and Value-At-Risk”, *The Review of Financial Studies*, Vol.27, No.2, pp.373~403.
- (15)Allahrakha, M., Cetina, J. and Munyan, B., 2018, “Do Higher Capital Standards Always Reduce Bank Risk? The Impact of The Basel Leverage Ratio on The US Triparty Repo Market”, *Journal of Financial Intermediation*, Vol.34, pp.3~16.
- (16)Baron, M., Verner, E. and Xiong, W., 2021, “Banking Crises Without Panics”, *The Quarterly Journal of Economics*, Vol.136, No.1, pp.51~113.
- (17)Bhagat, S., Bolton, B. and Lu, J., 2015, “Size, Leverage, And Risk-Taking of Financial Institutions”, *Journal of Banking & Finance*, Vol.59, pp.520~537.
- (18)Bianchi, D., Büchner, M. and Tamoni, A., 2021, “Bond Risk Premiums with Machine Learning”, *The Review of Financial Studies*, Vol.34, No.2, pp.1046~1089.
- (19)Brandao-Marques, L., Correa, R. and Sapriz, H., 2020, “Government Support, Regulation, and Risk Taking in the Banking Sector”, *Journal of Banking & Finance*, Vol.112, 105284.
- (20)Brownlees, C. and Engle, R. F., 2017, “SRISK: A Conditional Capital Shortfall Measure of Systemic Risk”, *The Review of Financial Studies*, Vol.30, No.1, pp.48~79.
- (21)Brož, V. and Kočenda, E., 2022, “Mortgage-Related Bank Penalties and Systemic Risk Among US Banks”, *Journal of International Money and Finance*, Vol.122, 102575.
- (22)Chen, W., Xu, H., Jia, L. and Gao, Y., 2021, “Machine Learning Model for Bitcoin Exchange Rate Prediction Using Economic and Technology Determinants”, *International Journal of Forecasting*, Vol.37, No.1, pp.28~43.
- (23)Chodorow-Reich, G. and Falato, A., 2022, “The Loan Covenant Channel: How Bank Health Transmits to The Real Economy”, *The Journal of Finance*, Vol.77, No.1, pp.85~128.
- (24)Choi, D. B., Holcomb, M. R. and Morgan, D. P., 2020, “Bank Leverage Limits and Regulatory Arbitrage: Old Question-New Evidence”, *Journal of Money, Credit and Banking*, Vol.52, No.S1, pp.241~266.
- (25)Coimbra, N., Kim, D. and Rey, H., 2022, “Central Bank Policy and The Concentration of Risk: Empirical Estimates”, *Journal of Monetary Economics*, Vol.125, pp.182~198.
- (26)Coimbra, N. and Rey, H., 2024, “Financial Cycles with Heterogeneous Intermediaries”, *Review of Economic Studies*, Vol.91, No.2, pp.817~857.
- (27)DeLL’Ariccia, G., Laeven, L. and Marquez, R., 2014, “Real Interest Rates, Leverage, And Bank Risk-Taking”, *Journal of Economic Theory*, Vol.149, pp.65~99.
- (28)Duarte, F. and Eisenbach, T. M., 2021, “Fire-Sale Spillovers and Systemic Risk”, *The Journal of Finance*, Vol.76, No.3, pp.1251~1294.
- (29)Fatás, A. and Summers, L. H., 2018, “The Permanent Effects of Fiscal Consolidations”, *Journal of International Economics*, Vol.112, pp.238~250.
- (30)Gao, Y., Shang, H. L. and Yang, Y., 2019, “High-Dimensional Functional Time Series Forecasting: An Application to Age-Specific Mortality Rates”, *Journal of Multivariate Analysis*, Vol.170, pp.232~243.
- (31)Gorton, G. and Ordóñez, G., 2020, “Good Booms, Bad Booms”, *Journal of the European Economic Association*, Vol.18, No.2, pp.618~

665.

(32) Goulet Coulombe, P., Leroux, M., Stevanovic, D. and Surprenant, S., 2022, "How Is Machine Learning Useful for Macroeconomic Forecasting?", *Journal of Applied Econometrics*, Vol.37, No.5, pp.920~964.

(33) Gu, S., Kelly, B. and Xiu, D., 2020, "Empirical Asset Pricing Via Machine Learning", *The Review of Financial Studies*, Vol.33, No.5, pp.2223~2273.

(34) Hagendorff, J., Saunders, A., Steffen, S. and Vallasca, F., 2021, "The Wolves of Wall Street? Managerial Attributes and Bank Risk", *Journal of Financial Intermediation*, Vol.47, 100921.

(35) Jing, Z., Liu, Z., Qi, L. and Zhang, X., 2022, "Spillover Effects of Banking Systemic Risk on Firms in China: A Financial Cycle Analysis", *International Review of Financial Analysis*, Vol.82, 102171.

(36) Leippold, M., Wang, Q. and Zhou, W., 2022, "Machine Learning in The Chinese Stock Market", *Journal of Financial Economics*, Vol.145, No.2, pp.64~82.

(37) Li, Z., Han, J. and Song, Y., 2020, "On the Forecasting of High-Frequency Financial Time Series Based on ARIMA Model Improved by Deep Learning", *Journal of Forecasting*, Vol.39, No.7, pp.1081~1097.

(38) Machado, J. A. and Silva, J. S., 2019, "Quantiles Via Moments", *Journal of Econometrics*, Vol.213, No.1, pp.145~173.

(39) Mian, A. and Sufi, A., 2009, "The Consequences of Mortgage Credit Expansion: Evidence from The US Mortgage Default Crisis", *The Quarterly Journal of Economics*, Vol.124, No.4, pp.1449~1496.

(40) Mian, A. and Sufi, A., 2022, "Credit Supply and Housing Speculation", *The Review of Financial Studies*, Vol.35, No.2, pp.680~719.

(41) Mian, A., Sufi, A. and Verner, E., 2020, "How Does Credit Supply Expansion Affect the Real Economy? The Productive Capacity and Household Demand Channels", *The Journal of Finance*, Vol.75, No.2, pp.949~994.

(42) Mourouzidou-Damtsa, S., Milidonis, A. and Stathopoulos, K., 2019, "National Culture and Bank Risk-taking", *Journal of Financial Stability*, Vol.40, pp.132~143.

(43) Procasky, W. J. and Yin, A., 2022, "Forecasting High-Yield Equity and CDS Index Returns: Does Observed Cross-Market Information Flow Have Predictive Power?", *Journal of Futures Markets*, Vol.42, No.8, pp.1466~1490.

(44) Richter, B., Schularick, M. and Wachtel, P., 2021, "When to Lean Against the Wind", *Journal of Money, Credit and Banking*, Vol.53, No.1, pp.5~39.

(45) Rieger, M. O., Wang, M. and Hens, T., 2015, "Risk Preferences around the World", *Management Science*, Vol.61, No.3, pp.637~648.

(46) Schularick, M. and Taylor, A. M., 2012, "Credit Booms Gone Bust: Monetary Policy, Leverage Cycles, And Financial Crises, 1870~2008", *The American Economic Review*, Vol.102, No.2, pp.1029~1061.

Can Risk Preference Become a Forward-Looking Indicator of Financial Risk in China? New Evidence from Cutting-edge Machine Learning Approaches

Yang Zihui^{a,b}, Li Dongcheng^c and Chen Yutian^a

(a. School of Finance, Shanghai University of Finance and Economics; b. Dishui Lake Advanced Finance Institute, Shanghai University of Finance and Economics; c. School of Economics and Finance, South China University of Technology)

Abstract: In recent years, uncertainty in the global financial market has soared and financial system has experienced intensified shocks. The construction and enhancement of a risk early-warning system for financial institutions to prevent and mitigate financial risks has been a high priority for the Chinese regulatory authorities. The 2007 subprime mortgage crisis and the bankruptcy of Silicon Valley Bank in 2023 illustrate that a substantial rise in bank risk-taking is the major cause of credit expansion and even the accelerated accumulation of financial risks. In view of this, this study, drawing on balance sheet data, accurately measures China's banking risk-taking and employs cutting-edge machine learning approaches for proactive financial risk forecasting. The findings indicate that risk-taking indicators are predictive of financial risk in China. Among them, large banks have higher asset-weighted risk-taking, while city commercial banks and rural financial institutions have relatively higher unweighted risk-taking. Additionally, during periods of high risk, risk-taking among financial institutions exacerbates financial market fluctuations and can even trigger financial risk. Furthermore, cutting-edge machine learning approaches provide stable and effective predictions of bank risks in China. Moreover, when constructing a predictive model based on risk-taking indicators, there has been a significant improvement in the out-of-sample predictive goodness of fit, compared to traditional regulatory indicators such as the bank leverage. Building on these insights, this paper proposes some policy suggestions on implementing differentiated management based on bank risk-taking and integrating machine learning methods to enhance real-time financial risk monitoring. These measures aim to bolster the stability of China's financial system and refine its comprehensive and forward-looking early warning system for financial risks.

Keywords: bank risk preference; financial risk; risk forecasting; machine learning

Can Risk Preference Become a Forward-Looking Indicator of Financial Risk in China? New Evidence from Cutting-edge Machine Learning Approaches

Yang Zihui^{a,b}, Li Dongcheng^c and Chen Yutian^a

(a. School of Finance, Shanghai University of Finance and Economics; b. Dishui Lake Advanced Finance Institute, Shanghai University of Finance and Economics; c. School of Economics and Finance, South China University of Technology)

Summary: Existing research indicates that traditional regulatory indicators such as bank leverage may not accurately reflect the financial risks of banks. Furthermore, the existing literature in this field still lacks a comprehensive analysis of the influencing factors of financial risk from the perspective of bank risk preference. Moreover, the majority of existing research utilizes regression analysis, causality test, and other methods within traditional analytical frameworks to forecast financial risk, overlooking the non-linear and asymmetric characteristics of financial risk outbreaks. Therefore, accurately predicting financial risk in China's banking sector using cutting-edge machine learning methods, and conducting a comprehensive comparative analysis of the prediction capabilities of various models for financial risk within a unified framework, is essential for timely adjustments to risk prevention policies in line with actual economic conditions.

In light of this, this article employs the most recently developed indicators of banking sector risk preference, based on bank balance sheet data, to accurately measure the risk preference of Chinese banks from 2009–2020, and analyzes how such behavior drives the evolution of financial risk. Concurrently, we apply quantile regression methods to investigate the heterogeneous effects of risk preference on financial risk across different quantiles. Building on this foundation, we further employ cutting-edge machine learning approaches to predict financial risk, highlighting the crucial forward-looking role of risk preference indicators in early warning systems. In addition, we also conducted a comparative analysis of the predictive capabilities of various models, accurately identifying the optimal risk forecasting model.

The findings of this article are as follows. (1) There is a notable heterogeneity in risk preference among banks, with urban commercial banks and rural financial institutions exhibiting a higher unweighted risk preference, while the weighted risk preference of large commercial banks is relatively higher. (2) Risk preference exerts a significant positive influence on financial risk, and the impact coefficient increases significantly as the quantile level increases. (3) Random forests and gradient boosting regression trees exhibit significantly higher out-of-sample R^2 than traditional models such as least squares regression. Furthermore, the predictive power of these machine learning models remains stable and effective across different time periods. (4) Compared to the capital adequacy ratio (leverage), risk preference indicators provide incremental information, which is more conducive to accurately predicting banking risks.

Based on the above-mentioned research conclusions that are highly enlightening, this article offers three insights: (1) Regulatory authorities should develop and refine a bank risk prevention framework that centers on capital adequacy ratios while also incorporating bank risk preference as a vital complement. (2) We should implement differentiated management tailored to varying risk and market conditions, while ensuring the rational allocation and integrated oversight of regulatory and resolution resources. (3) Regulatory authorities should optimize the financial risk early-warning system by integrating machine learning methods, aiming to bolster the proactiveness and effectiveness of risk prevention.

Keywords: bank risk preference; financial risk; risk forecasting; machine learning

JEL Classification: G01, G10, G21

附录一 具体变量说明

附表1为变量说明表,阐述各变量的含义以及数据来源。

附表1 变量说明表

变量名	变量含义	数据来源
Panel A: 个体指标		
<i>acc</i>	参考斯隆(1996)的定义, $acc = [(\Delta CA - \Delta CASH) - (\Delta CL - \Delta STD - \Delta TP) - Dep] / TA$, 其中 <i>CA</i> 、 <i>CASH</i> 、 <i>CL</i> 、 <i>STD</i> 、 <i>TP</i> 、 <i>Dep</i> 和 <i>TA</i> 分别表示流动性资产、现金、流动性负债、计入流动性负债的债务、应付所得税、折旧和摊销费用以及总资产。	CSMAR 数据库
<i>absacc</i>	<i>acc</i> 的绝对值	CSMAR 数据库
<i>agr</i>	总资产的变化率	CSMAR 数据库
<i>bm</i>	账面市值比	CSMAR 数据库
<i>cash</i>	现金与现金等价物与总资产的比	CSMAR 数据库
<i>cashdebt</i>	现金收入除以负债总额	CSMAR 数据库
<i>cashspr</i>	市值加长期债务减总资产再除以现金与现金等价物	CSMAR 数据库
<i>cfp</i>	经营现金流除以市值	CSMAR 数据库
<i>chato</i>	资产周转率的变化	CSMAR 数据库
<i>chcsho</i>	流通股数量的变化率	CSMAR 数据库
<i>chempia</i>	按行业均值调整的员工数量变化	CSMAR 数据库
<i>chmom</i>	$t-6$ 到 $t-1$ 月累积收益率减 $t-12$ 到 $t-7$ 月累积收益率	CSMAR 数据库
<i>chpm</i>	利润率的变化	CSMAR 数据库
<i>chtx</i>	税收的变化率	CSMAR 数据库
<i>cinvest</i>	企业投资	CSMAR 数据库
<i>divi</i>	发放股息的虚拟变量	CSMAR 数据库
<i>divo</i>	停止发放股息的虚拟变量	CSMAR 数据库
<i>dolvol</i>	成交额的自然对数	CSMAR 数据库
<i>dy</i>	发放的股息总额除以市值	CSMAR 数据库
<i>egr</i>	权益账面价值的变化率	CSMAR 数据库
<i>gma</i>	收入减去销售成本除以 $t-1$ 期总资产	CSMAR 数据库
<i>hire</i>	员工数量的变化率	CSMAR 数据库
<i>idiovol</i>	个股特殊回报率的波动率	CSMAR 数据库
<i>ill</i>	收益率的绝对值除以交易量	CSMAR 数据库
<i>invest</i>	资本支出和存货的变化	CSMAR 数据库
<i>lev</i>	总负债除以市值	CSMAR 数据库
<i>lgr</i>	总负债的季度变化率	CSMAR 数据库
<i>maxret</i>	日度收益率的最大值	CSMAR 数据库
<i>mom1m</i>	1 个月的累积收益率	CSMAR 数据库
<i>mom6m</i>	$t-6$ 到 $t-1$ 月累积收益率	CSMAR 数据库
<i>mom12m</i>	$t-12$ 到 $t-1$ 月累积收益率	CSMAR 数据库
<i>mve</i>	市值的自然对数	CSMAR 数据库
<i>nincr</i>	盈利增加的时间跨度	CSMAR 数据库
<i>operprof</i>	营业利润除以股东权益	CSMAR 数据库
<i>pchcapx_ia</i>	按行业均值调整的资本支出变化率	CSMAR 数据库
<i>pchgm_pchsale</i>	毛利率的变化率减去销售额的变化率	CSMAR 数据库
<i>pectacc</i>	分子与 <i>acc</i> 相同, 分母为净收入的绝对值	CSMAR 数据库
<i>rd</i>	虚拟变量, 若研发费用占总资产比例超过 5% 则为 1	CSMAR 数据库
<i>rd_mve</i>	研发费用除以市值	CSMAR 数据库
<i>rd_sale</i>	研发费用除以销售额	CSMAR 数据库
<i>realestate</i>	投资性房地产除以固定资产	CSMAR 数据库
<i>volatility</i>	日度收益率的标准差	CSMAR 数据库
<i>roaq</i>	资产收益率	CSMAR 数据库
<i>roavol</i>	资产收益率的标准差	CSMAR 数据库
<i>roeq</i>	净资产收益率	CSMAR 数据库
<i>roic</i>	投资资本收益率	CSMAR 数据库
<i>rsup</i>	销售额的变化除以市值	CSMAR 数据库
<i>salecash</i>	销售额除以现金及现金等价物	CSMAR 数据库
<i>sgr</i>	销售额的变化率	CSMAR 数据库
<i>sp</i>	销售额除以市值	CSMAR 数据库
<i>std_dolvol</i>	交易量的标准差	CSMAR 数据库
<i>std_turn</i>	换手率的标准差	CSMAR 数据库
<i>stdacc</i>	<i>acc</i> 的标准差	CSMAR 数据库
<i>stdcf</i>	净现金流量除以销售额的标准差	CSMAR 数据库
<i>tang</i>	$(\text{现金} + 0.715 \times \text{应收账款} + 0.547 \times \text{存货} + 0.535 \times \text{固定资产}) / \text{总资产}$	CSMAR 数据库
<i>tb</i>	应税收入	CSMAR 数据库

<i>turn</i>	股份周转率	CSMAR 数据库
<i>zerotrade</i>	零交易日的数量	CSMAR 数据库
<i>largestholderrate</i>	最大股东占比	CSMAR 数据库
<i>top10holderrate</i>	前十股东占比	CSMAR 数据库
<i>soe</i>	虚拟变量,若股权性质为国有则为 1	CSMAR 数据库
<i>private</i>	虚拟变量,若股权性质为民营则为 1	CSMAR 数据库
<i>foreign</i>	虚拟变量,若股权性质为外资则为 1	CSMAR 数据库
<i>other</i>	虚拟变量,若股权性质为其他则为 1	CSMAR 数据库
<i>CapAdequacy</i>	资本充足率	Wind 数据库
<i>CapAdequacy_T1</i>	一级资本充足率	Wind 数据库
<i>CapAdequacy_CT1</i>	核心一级资本充足率	Wind 数据库
<i>Leverage</i>	银行杠杆	Wind 数据库
<i>npl</i>	不良贷款率	Wind 数据库
<i>nplcoverage</i>	不良贷款拨备覆盖率	Wind 数据库
<i>netinterestmargin</i>	净息差	Wind 数据库
<i>netinterestspread</i>	净利差	Wind 数据库
<i>noninterestincome</i>	非利息收入占比	Wind 数据库
<i>loanlossprovision</i>	贷款损失准备充足率	Wind 数据库
<i>yield</i>	生息资产收益率	Wind 数据库
<i>cost</i>	计息负债成本率	Wind 数据库
<i>costincomeratio</i>	成本收入比	Wind 数据库
<i>loandepositratio</i>	存贷款比率	Wind 数据库
<i>unRiskTaking</i>	银行业风险偏好	作者计算
<i>wiRiskTaking</i>	规模加权的银行业风险偏好	作者计算
Panel B: 宏观指标		
<i>dp</i>	股息价格比	CSMAR 数据库
<i>de</i>	派息率	CSMAR 数据库
<i>bm_mkt</i>	市场账面市值比	CSMAR 数据库
<i>svar</i>	上证综指日收益率的平方和	CSMAR 数据库
<i>ep</i>	收益价格比	CSMAR 数据库
<i>ntis</i>	净股本扩张	Wind 数据库
<i>tms</i>	期限利差	Wind 数据库
<i>infl</i>	通货膨胀率	Wind 数据库
<i>mtr</i>	市场的月成交量	CSMAR 数据库
<i>m2gr</i>	M2 月度增长率	Wind 数据库
<i>itgr</i>	国际贸易额增长率	Wind 数据库
<i>vadgr</i>	工业增加值当月同比	Wind 数据库

附录二 剔除特定个体或时期的稳健性分析

附表 2 展示了剔除“中、农、工、建”4 家大型商业银行的稳健性分析结果。其中,模型 I~II、模型 III~IV、模型 V~VI 以及模型 VII~VIII 分别为剔除中国银行、农业银行、工商银行以及建设银行后的分样本回归,风险偏好的系数均在 10% 水平下显著;而模型 IX~X 则同时剔除了“中、农、工、建”4 家国有大型商业银行,结果依然保持稳健。

附表 2 剔除大型商业银行样本的稳健性检验

	模型 I	模型 II	模型 III	模型 IV	模型 V	模型 VI	模型 VII	模型 VIII	模型 IX	模型 X
	<i>MES</i> ⁺¹	<i>VaR</i> ⁺¹	<i>MES</i> ⁺¹	<i>VaR</i> ⁺¹	<i>MES</i> ⁺¹	<i>VaR</i> ⁺¹	<i>MES</i> ⁺¹	<i>VaR</i> ⁺¹	<i>MES</i> ⁺¹	<i>VaR</i> ⁺¹
单位资产风险偏好	0.041** [0.024]	0.026** [0.034]	0.040** [0.021]	0.026** [0.024]	0.033* [0.080]	0.021* [0.098]	0.041*** [0.008]	0.028*** [0.007]	0.033* [0.071]	0.020* [0.084]
<i>MES</i> [*]	0.573*** [0.000]		0.575*** [0.000]		0.579*** [0.000]		0.566*** [0.000]		0.550*** [0.000]	
<i>VaR</i> [*]		0.586*** [0.000]		0.590*** [0.000]		0.593*** [0.000]		0.560*** [0.000]		0.546*** [0.000]
个体固定效应	是	是	是	是	是	是	是	是	是	是
控制变量	是	是	是	是	是	是	是	是	是	是
观测值	2497	2497	2505	2505	2497	2497	2497	2497	2112	2112
adj.R ²	0.488	0.445	0.488	0.449	0.491	0.453	0.507	0.484	0.495	0.469

注: (1) 上表中的基准回归方程为: $SysRisk_{i,t+1} = \alpha + \beta RiskTaking_{i,t} + \theta SysRisk_{i,t} + \gamma Controls_{i,t} + \delta_i + \epsilon_{i,t}$, 被解释变量为金融风险指标, 主要解释变量为银行风险偏好; (2) 控制变量包括账面市值比、银行规模、M2 增长率、期限利差、市场净股本扩张、股息发放率、总资产周转率、营业利润率、投资性房地产以及有形资产, 后续附表 3~附表 5 与此相同, 不再赘述; (3) *, **, *** 分别代表系数在 90%、95%、99% 的置信水平下显著, 方括号内为 p 值, 依据稳健标准误计算, 后续附表 3~附表 6 相同, 不再赘述。

此外, 2020 年我国经济严重承压, 各银行或被动地进行信贷扩张, 从而提升了银行业风险。因此, 我们进一步剔除对应年份的样本, 以检验结论的稳健性。附表 3 的分析结果显示, 与正文表 4 结论保持一致, 风险偏好的回归系数仍旧在 10% 水平下显著。

附表3 剔除2020年样本的稳健性检验

	模型 I	模型 II	模型 III	模型 IV	模型 V	模型 VI
	MES^{*1}	VaR^{*1}	MES^{*1}	VaR^{*1}	MES^{*1}	VaR^{*1}
单位资产风险偏好	0.043** [0.019]	0.032** [0.012]	0.044** [0.019]	0.029** [0.018]	0.035* [0.071]	0.028** [0.022]
MES	0.653*** [0.000]		0.583*** [0.000]		0.630*** [0.000]	
VaR		0.648*** [0.000]		0.595*** [0.000]		0.607*** [0.000]
个体固定效应	是	是	是	是	是	是
控制变量	是	是	是	是	是	是
观测值	2251	2251	2580	2580	1783	1783
adj.R ²	0.579	0.525	0.497	0.457	0.593	0.556

注：(1)上表中的基准回归方程为： $SysRisk_{i,t+1} = \alpha + \beta RiskTaking_{i,t} + \theta SysRisk_{i,t} + \gamma Controls_{i,t} + \delta + \epsilon_{i,t}$ ，被解释变量为金融风险指标，主要解释变量为银行风险偏好；(2)模型 I ~ II、模型 III ~ IV 分别剔除 2020 年子样本，2020 年“中、农、工、建”4 家大型商业银行的子样本展开回归分析，而模型 V ~ VI 则在个体层面剔除“中、农、工、建”4 家大型商业银行的基础上，进一步从时间层面剔除了 2020 年的样本。

附录三

(一)控制银行杠杆

附表 4 为仅控制杠杆倍数的稳健性检验，展示了剔除杠杆因素后，银行风险偏好对金融风险的影响。

附表4 控制杠杆倍数的稳健性检验

	模型 I	模型 II	模型 III	模型 IV
	MES^{*1}	MES^{*1}	VaR^{*1}	VaR^{*1}
单位资产风险偏好	0.040** [0.021]		0.026** [0.028]	
规模加权风险偏好		0.026 [0.173]		0.019* [0.050]
杠杆倍数	-0.009 [0.641]	-0.007 [0.715]	-0.003 [0.846]	-0.002 [0.914]
MES	0.580*** [0.000]	0.583*** [0.000]		
VaR			0.596*** [0.000]	0.598*** [0.000]
个体固定效应	是	是	是	是
控制变量	是	是	是	是
观测值	2628	2628	2628	2628
adj.R ²	0.493	0.492	0.453	0.452

注：上表中的基准回归方程为： $SysRisk_{i,t+1} = \alpha + \beta X_{i,t} + \theta SysRisk_{i,t} + \gamma Controls_{i,t} + \delta + \epsilon_{i,t}$ ，被解释变量为金融风险指标，主要解释变量 $X_{i,t}$ 包括银行风险偏好与银行杠杆倍数。

(二)控制银行资本充足率

附表 5 为仅控制资本充足率的稳健性检验，展示了剔除资本充足率因素后银行风险偏好对金融风险的影响。

附表5 控制资本充足率的稳健性检验

	模型 I	模型 II	模型 III	模型 IV	模型 V	模型 VI	模型 VII	模型 VIII	模型 IX	模型 X	模型 XI	模型 XII
	MES^{*1}	MES^{*1}	MES^{*1}	MES^{*1}	MES^{*1}	MES^{*1}	VaR^{*1}	VaR^{*1}	VaR^{*1}	VaR^{*1}	VaR^{*1}	VaR^{*1}
单位资产风险偏好	0.045** [0.027]	0.048** [0.017]	0.049** [0.016]				0.026* [0.070]	0.030** [0.030]	0.031** [0.030]			
规模加权风险偏好				0.029 [0.161]	0.030 [0.132]	0.029 [0.136]				0.019* [0.071]	0.022** [0.039]	0.022** [0.041]
资本充足率	0.005 [0.853]			-0.000 [0.994]			-0.024 [0.222]			-0.027 [0.149]		
一级资本充足率		0.040 [0.195]			0.034 [0.246]			0.023 [0.313]			0.019 [0.378]	
核心一级资本充足率			0.047 [0.171]			0.039 [0.221]			0.023 [0.311]			0.019 [0.386]
MES	0.581*** [0.000]	0.578*** [0.000]	0.578*** [0.000]	0.583*** [0.000]	0.581*** [0.000]	0.580*** [0.000]						
VaR							0.594*** [0.000]	0.593*** [0.000]	0.593*** [0.000]	0.594*** [0.000]	0.594*** [0.000]	0.594*** [0.000]
个体固定效应	是	是	是	是	是	是	是	是	是	是	是	是
控制变量	是	是	是	是	是	是	是	是	是	是	是	是

观测值	2516	2510	2516	2516	2510	2516	2516	2510	2516	2516	2510	2516
adj.R ²	0.484	0.484	0.485	0.484	0.483	0.484	0.444	0.444	0.444	0.444	0.443	0.444

注：上表中的基准回归方程为： $SysRisk_{i,t+1} = \alpha + \beta X_{i,t} + \theta SysRisk_{i,t} + \gamma Controls_{i,t} + \delta_i + \epsilon_{i,t}$ ，被解释变量为金融风险指标，主要解释变量 $X_{i,t}$ 包括银行风险偏好与资本充足率。

附录四 银行业风险偏好与金融风险的因果关系检验

本文结合杜米特雷斯库和赫林(2012)提出的面板格兰杰因果检验方法,验证银行业风险偏好与金融风险之间的关联关系。附表6中基于Z检验与 $\tilde{Z}$ 检验的统计量,均拒绝了“不存在从银行业风险偏好到金融风险的因果关系”的原假设,这就意味着银行业风险偏好对金融风险存在显著的因果效应。

附表6 银行业风险偏好与金融风险的因果关系检验

Panel A: 单位资产风险偏好					
单位资产 风险偏好	金融风险	MES		VaR	
		(1) Z^{llbc}	(2) $\tilde{Z}^{llbc}$	(1) Z^{llbc}	(2) $\tilde{Z}^{llbc}$
t 期	t 期	7.253*** [0.000]	3.026*** [0.002]	65.382*** [0.000]	8.747*** [0.000]
t 期	$t+1$ 期	7.989*** [0.000]	2.873*** [0.004]	28.891*** [0.000]	5.771*** [0.000]
t 期	$t+2$ 期	8.773*** [0.000]	3.420*** [0.001]	10.842*** [0.000]	6.201*** [0.000]
t 期	$t+3$ 期	10.509*** [0.000]	4.047*** [0.000]	12.636*** [0.000]	6.657*** [0.000]
t 期	$t+4$ 期	10.088*** [0.000]	4.698*** [0.000]	8.330*** [0.000]	7.346*** [0.000]
t 期	$t+5$ 期	8.124*** [0.000]	4.792*** [0.000]	12.843*** [0.000]	7.620*** [0.000]
t 期	$t+6$ 期	7.397*** [0.000]	5.469*** [0.000]	13.730*** [0.000]	8.967*** [0.000]
t 期	$t+7$ 期	6.797*** [0.000]	5.649*** [0.000]	20.983*** [0.000]	8.926*** [0.000]
t 期	$t+8$ 期	12.016*** [0.000]	6.456*** [0.000]	30.625*** [0.000]	9.015*** [0.000]
t 期	$t+9$ 期	12.084*** [0.000]	6.425*** [0.000]	16.494*** [0.000]	8.678*** [0.000]
t 期	$t+10$ 期	13.069*** [0.000]	7.077*** [0.000]	10.644*** [0.000]	10.044*** [0.000]
t 期	$t+11$ 期	12.011*** [0.000]	7.947*** [0.000]	11.183*** [0.000]	10.636*** [0.000]
t 期	$t+12$ 期	11.413*** [0.000]	10.935*** [0.000]	14.515*** [0.000]	13.923*** [0.000]
Panel B: 规模加权风险偏好					
规模加权 风险偏好	金融风险	MES		VaR	
		(1) Z^{llbc}	(2) $\tilde{Z}^{llbc}$	(1) Z^{llbc}	(2) $\tilde{Z}^{llbc}$
t 期	t 期	20.486*** [0.000]	2.295*** [0.022]	18.399*** [0.000]	4.936*** [0.000]
t 期	$t+1$ 期	15.897*** [0.000]	2.153*** [0.031]	12.218*** [0.000]	5.191*** [0.000]
t 期	$t+2$ 期	7.075*** [0.000]	2.763*** [0.006]	11.092*** [0.000]	5.374*** [0.000]
t 期	$t+3$ 期	4.424*** [0.000]	3.300*** [0.001]	6.666*** [0.000]	5.797*** [0.000]
t 期	$t+4$ 期	8.492*** [0.000]	4.022*** [0.000]	7.608*** [0.000]	6.653*** [0.000]
t 期	$t+5$ 期	5.105*** [0.000]	4.159*** [0.000]	7.841*** [0.000]	6.904*** [0.000]
t 期	$t+6$ 期	11.214*** [0.000]	4.918*** [0.000]	9.419*** [0.000]	8.417*** [0.000]
t 期	$t+7$ 期	8.089*** [0.000]	5.111*** [0.000]	12.980*** [0.000]	8.297*** [0.000]
t 期	$t+8$ 期	11.932*** [0.000]	5.743*** [0.000]	31.584*** [0.000]	8.350*** [0.000]
t 期	$t+9$ 期	10.342*** [0.000]	5.877*** [0.000]	15.491*** [0.000]	8.119*** [0.000]
t 期	$t+10$ 期	11.569*** [0.000]	6.553*** [0.000]	10.141*** [0.000]	9.566*** [0.000]
t 期	$t+11$ 期	11.118*** [0.000]	7.474*** [0.000]	10.685*** [0.000]	10.159*** [0.000]
t 期	$t+12$ 期	11.065*** [0.000]	10.599*** [0.000]	14.175*** [0.000]	13.595*** [0.000]

注：(1)上表中原假设为“不存在从银行业风险偏好到金融风险的因果关系”。(2)遵循杜米特雷斯库和赫林(2012)的做法,由于样本并不满足T显著大于N的先决条件,应优先考虑使用 $\tilde{Z}^{llbc}$ 统计量;同时,为了保障本文实证结果的稳健性,我们也提供了 Z^{llbc} 检验统计量的分析结果。

附录五 正则化的线性回归方法

在目标函数上附加惩罚项参数的正则化方法是应对“过拟合”问题的常见方法。该方法通过降低模型的样本内拟合性能,以提高样本外预测能力。具体而言,假设线性的金融风险预测模型如下所示:

$$y_{i,t+1} = g(z_{i,t}; \theta) + \varepsilon_{i,t} = z_{i,t}'\theta + \varepsilon_{i,t} \quad (\text{A.1})$$

其中, $g(\cdot)$ 为衡量金融风险与预测因子 $z_{i,t}$ 之间相互关系的函数,而 θ 是包含截距项的系数向量,采用标准的最小二乘估计如下目标函数:

$$L(\theta) = \frac{1}{NT} \sum_{i=1}^N \sum_{t=1}^T (y_{i,t+1} - g(z_{i,t}; \theta))^2 \quad (\text{A.2})$$

通过最小化损失函数 $L(\theta)$, 即可得到 OLS 的系数估计 $\hat{\theta}$ 。然而,损失函数 $L(\theta)$ 容易受到样本中异常值的影响,这严重地削弱了 OLS 估计的预测性能。为了克服这个问题,在机器学习领域常使用 Huber 形式的目标函数进行估计:

$$L_H(\theta) = \frac{1}{NT} \sum_{i=1}^N \sum_{t=1}^T H(y_{i,t+1} - g(z_{i,t}; \theta); M) \quad (\text{A.3})$$

$$H(x; M) = \begin{cases} x^2, & \text{if } |x| \leq M, \\ 2M|x| - M^2, & \text{if } |x| > M. \end{cases} \quad (\text{A.4})$$

Huber 形式的目标函数对大于阈值参数 M 的数值进行修正,以减轻异常值的影响。然而,预测因子 $z_{i,t}$ 中可能存在高度相关的冗余变量,从而导致估计效率的损失,因此,我们进一步采用正则化的线性回归模型 LASSO 与弹性网络,以克服高维度线性回归的缺

陷。上述两类方法均在原有目标函数的基础上增添惩罚项,使冗余变量的系数缩减为零,弹性网络方法的目标函数如下所示:


$$L_H^{Elastic}(\theta) = L_H(\theta) + \lambda(1-\rho) \sum_{j=1}^p |\theta_j| + \frac{1}{2} \rho \lambda \sum_{j=1}^p \theta_j^2 \quad (A.5)$$

其中, λ 为控制惩罚项大小的超参数, ρ 为惩罚项的权重参数。当权重参数 $\rho=0$ 时,弹性网络即退化为 LASSO 估计,由此得到 LASSO 的目标函数:

$$L_H^{LASSO}(\theta) = L_H(\theta) + \lambda \sum_{j=1}^p |\theta_j| \quad (A.6)$$

附录六 变量重要性分析

本文进一步结合变量重要性计算方法,计算对比各变量在预测金融风险方面的重要程度。附图1显示,风险偏好指标的重要性排序较高,在全部91个解释变量中位列第7,表明该指标对系统性金融风险具有前瞻性的预测能力^①。



附图1 变量重要性分析

注:(1)变量重要性根据各变量的基尼重要性(Gini importance)计算,具体计算方法详见门泽等(2009);(2)图中颜色越深,代表变量的重要性越强。(3)预测模型中共包含91个变量,但由于文章篇幅所限,图中仅列出前20位的重要变量。(4)热力图的每个单元格分别表示各变量结合不同预测模型在各年份子样本中的变量重要性。其中,横轴列示了子样本的年份与使用的预测模型,例如,“梯度提升2020年”表示采用截至2020前一年(即2019年)的数据,以梯度提升回归树方法拟合预测模型,并使用其对2020年的金融风险进行预测。(5)上图展示以边际期望损失作为因变量的分析结果,以在险价值作为因变量的分析结果备案。

注释

①中外文人名(机构名)对照:斯隆(Sloan);杜米特雷斯库(Dumitrescu);赫林(Hurlin);门泽(Menze)。

参考文献

- (1) Dumitrescu, E. I. and Hurlin, C., 2012, “Testing for Granger Non-Causality in Heterogeneous Panels”, *Economic modelling*, Vol.29, No.4, pp.1450~1460.
- (2) Menze, B. H., Kelm, B. M., Masuch, R., Himmelreich, U., Bachert, P., Petrich, W. and Hamprecht, F. A., 2009, “A Comparison of Random Forest and Its Gini Importance with Standard Chemometric Methods for The Feature Selection and Classification of Spectral Data”, *BMC Bioinformatics*, Vol.10, No.213, pp.1~16.
- (3) Sloan, R. G., 1996, “Do Stock Prices Fully Reflect Information in Accruals and Cash Flows About Future Earnings?”, *Accounting Review*, Vol.71, No.3, pp.289~315.