

基于 Expectile 回归森林模型的中国商业银行 收益率风险测度研究

严复雷¹, 余晨曦¹, 张高勋²

(1. 西南科技大学经济管理学院, 四川 绵阳 621010; 2. 西南科技大学理学院, 四川 绵阳 621010)

摘要: 有效防范和化解风险是金融业的永恒主题。在当前全球化且复杂严峻的经济金融环境下, 提高对商业银行收益率风险的预测能力, 并及时采取措施防范化解风险具有重要的现实意义。选取 2013 年 1 月至 2022 年 12 月 A 股上市商业银行的月度数据, 构建非参数 Expectile 回归森林(ERF)风险预测模型对中国商业银行尾部风险进行测度, 并将测度结果与传统的期望分位数回归(ER)模型和 Expectile 回归树(ERT)模型测度结果进行比较各自的预测性能。结果表明, ERF 模型在对商业银行收益率风险测度性能表现出众, 在不同风险水平下 ERF 模型的估计和预测能力显著优于 ERT 和 ER 模型; 进一步分析发现, 四大类商业银行尾部风险预测中误差最小和最大者分别是全国性大型商业银行和地方性农村商业银行, 而股份制商业银行和地方性城市商业银行的误差值相当。运用 ERF 测度商业银行收益率风险为商业银行防范风险提供了重要决策依据, 并有助于商业银行风险管理, 为金融监管部门提供分类分层监管商业银行收益率风险的重要政策支持。

关键词: Expectile 回归森林; 商业银行; 收益率风险; Bagging 算法

中图分类号: F831.5 **文献标志码:** A **文章编号:** 1671-1807(2025)12-0141-11

有效防范和化解风险一直是我国金融业的永恒主题。2023 年中央金融工作会议强调, 做好金融工作必须以全面加强监管、防范化解风险为重点, 并牢牢守住不发生系统性金融风险的底线。2023 年 3 月美国硅谷银行(简称 SVB)的破产对全球资本市场造成不同程度的恐慌和不确定性^[1-2], 再次给金融界敲响了银行金融风险蔓延的警钟, 警示银行业要加强事前监管和风险监测, 完善事后风险处置机制^[3], 还要增强风险管控意识与能力, 加大金融审慎监管力度^[4]。2020 年以来经受新冠肺炎疫情冲击、国内经济下行等多重考验, 全球动荡源和风险点增多, 面对国际经济金融环境更趋复杂严峻, 中国银行业风险防控工作将面对新挑战。

金融机构的收益损失往往与尾部风险相关, 而尾部风险又极易引起系统性风险的发生。所以, 提高预测银行金融极端事件造成的收益率损失风险能力以及及时防范化解风险成为一个紧迫的课题。尾部风险在极端事件发生时加剧风险传染和扩

散^[5], 所带来的影响由小到大, 由弱变强, 最终量变引起系统的质变^[6]。测度尾部风险以在险价值(value at risk, VaR)和预期不足(expected shortfall, ES)为代表的分位数度量法占据主流。据此, 很多学者在基础方法上改进创新, 提出各种替代 VaR 和 ES 的风险度量工具。

一方面, 在 VaR 基础上 Adrian 和 Brunnermeier^[7]首次提出一种以金融机构陷入困境为条件的下行风险衡量标准——条件在险价值(conditional value at risk, CoVaR), 度量系统性风险及银行业务间的风险溢出效应来判断单个金融机构系统性风险的边际贡献度, 并定义金融机构对系统性风险的边际贡献为 ΔCoVaR , 即机构陷入困境的 CoVaR 与机构处于正常状态下的 CoVaR 之差。此后, 条件在险价值在国内外相关研究领域被广泛运用并得以拓展。De Mendonça 和 Silva^[8]采用 ΔCoVaR 框架分析巴西银行业系统性风险, 并研究其决定因素; Huang 等^[9]构建条件在险价值(CoVaR)、边际

收稿日期: 2024-09-12

基金项目: 国家社会科学基金后期重点项目(20FJYA002)

作者简介: 严复雷(1975—), 男, 甘肃武威人, 博士, 教授, 研究方向为国际贸易和数字金融; 通信作者余晨曦(1999—), 女, 云南昭通人, 硕士研究生, 研究方向为金融风险; 张高勋(1977—), 男, 河南洛阳人, 博士, 副教授, 研究方向为量化投资和金融风险。

预期损失(MES)、系统影响指数(SII)和脆弱性指数(VI)四个风险指标检验我国上市银行系统性风险; Hao 和 Chen^[10]创新出 Vine Copula 分组 CoVaR 模型,证实了该模型比传统的 CoVaR 模型更能捕捉中国金融机构间的依赖关系。国内研究采用极端分位数回归度量单一金融机构的系统性风险边际贡献^[11],或用分位数回归结合 CoVaR 的方法量化中国上市银行的风险贡献率^[12-13],抑或针对金融数据随时间波动的特征构建 GARCH-CoVaR 模型,考察银行的系统性风险边际贡献和风险溢出效应^[14],分析各商业银行的系统重要性程度。

另一方面, Acharya 等^[15]在 ES 基础上提出边际预期不足(marginal expected shortfall, MES)和系统性预期不足(systemic expected shortfall, SES)以衡量每家银行对系统性金融风险的边际贡献,并实证检验金融机构的边际预期不足(MES)及其杠杆对系统预期不足(SES)的可预测性。随后 Brownlees 和 Engle^[16]提出用系统性风险指数(SRISK)衡量金融机构处于危机中的预期资本短缺。国内学者刘晓倩和周勇^[17]比较了两步核光滑 ES 估计和完全经验 ES 估计的优劣;刘吕科等^[18]回顾了国内外衡量系统性金融风险的方法并给出后续研究展望;赵进文等^[19]对 MES 和 CoVaR 两种度量系统性金融风险方法的联系与区别进行分析,指出在研究中应注意不同方法的应用环境;宋清华和姜玉东^[20]基于 MES 方法结合杠杆率和资产规模等因素对中国上市银行的系统性风险进行度量;张冰洁等^[21]提出 CoES 新模型测度了中国金融市场系统性风险贡献度。

然而伴随着经济金融环境日趋复杂以及不确定性增加,传统 VaR 存在不满足一致性公理^[22]且忽视了分位点左边损失情况的缺陷,ES 存在难以获得风险因素来源及其影响大小^[23]等问题。在现实中人们更关心能否更灵敏反映极端损失大小, VaR 和 ES 的效果却不太理想,由 Newey 和 Powell^[24]提出的期望分位数(Expectile)方法突破了这一难题。关于 Expectile 及其拓展模型的应用多集中于原油价格风险^[25-26]、股票或基金组合收益率波动^[27-29],而用于银行业风险度量的研究较少。由此,本文尝试采用期望分位数回归方法以测度中国商业银行尾部风险。

尾部风险虽然发生概率小,但具有传染性和加速器的放大效应,一旦发生而引发的金融风险不仅会对实体经济造成巨大负外部性,还会通过行业间

密切的业务往来传播至整个金融体系,进而引发系统性风险,危害性极强。所以分析银行风险背后的驱动成因是必要的。王妍和陈守东^[30]发现金融机构的杠杆率和规模对风险影响最为显著,此外张家臻和刘亚^[31]发现银行对市场的风险溢出受其自身经营状况的影响,其中就包含杠杆率和银行规模。随着世界政治经济格局日趋复杂,李洋等^[32]发现经济政策不确定性的提高会加剧金融机构的风险传染性及自身脆弱性,更会显著增加银行的风险水平^[33-34],进一步加剧其经营风险和信用风险并降低风险承担能力^[35],因此银行受到经济政策不确定性的影响更为深刻;Giglio 等^[36]认为金融市场的波动性与流动性是产生风险的原因。不仅如此,也有学者从商业银行风险承担的影响维度进行研究,如郭宜淳等^[37]研究发现金融科技的发展提高了行业竞争程度,并增加商业银行风险承担;李树凤^[38]基于银行业竞争与绿色信贷调节效应角度发现银行业竞争正向调节社会责任与银行风险承担的关系,而绿色信贷则相反。以往研究大多仅聚焦单一因素对风险的影响,少有在预测中同时考虑金融市场变量以包括更多的信息,提高对银行收益率风险预测的准确性。由此,本文尝试将银行规模、杠杆率、经济政策不确定性、金融市场流动性和波动性影响变量同时纳入模型中进行风险测度。

实际数据往往具有非线性特征。Yao 和 Tong^[39]提出的非参数期望回归模型进一步提高了模型对数据的预测能力。并且近年来,机器学习因处理多维变量的优势和良好的预测能力被广泛应用于分类和回归中,将机器学习方法与非参数期望回归相结合的研究数量大幅增加,并都取得了较为理想的结果。借鉴 Cai 等^[40]提出机器学习中的随机森林与 Expectile 回归相结合得到的一种新的非参数 Expectile 回归森林(expectile regression forest, ERF)模型,构建具有较高预测精度的上市商业银行尾部风险预测模型并检验其预测能力。随机森林模型可以不用考虑解释变量之间的相关性,所以该模型的优势在于克服了传统线性 Expectile 模型忽略解释变量间交互作用的局限性,并且采用 Bagging 集成法汇总多棵回归树,克服单一回归树预测性能差的缺点。

本文的创新之处在于:第一,ERF 模型目前主要应用于翼型叶片噪声数据、联合循环发电厂数据、白酒质量数据,但在商业银行尾部风险测度方面的应用极少。将基于 Bagging 算法的非参数

ERF 模型新颖地应用到中国商业银行尾部风险测度中,突破了传统风险测度方法的局限性,为银行业在风险预测方面提供新的思路和方法。并且将机器学习方法应用于经济学研究中,实现多学科交叉的同时也致力于对期望分位数回归方法的推广和实际应用。第二,以往研究大多仅分析单一因素对银行风险的影响,本文将银行杠杆率、资产规模、经济政策不确定性、金融市场波动性和流动性多个关键变量同时纳入模型中,实现对银行风险的多方位分析。通过综合考量这些因素,不仅提高风险管理的准确性和有效性,为商业银行完善风险防范机制提供较为全面和可靠的理论支持,同时也为银行业在应对外部环境变化时提供了更灵活的解决方案参考。

1 模型设定与方法说明

1.1 Exepctile 回归(ER)模型

Expectile 最早由 Newey 和 Powell^[24] 提出,并采用非对称最小二乘法(ALS)进行估计。最小化非对称平方损失函数得到的解就是 Expectile,它不需作任何分布假设,平方项也容易计算,并且 Bellini 和 Bernardino^[41] 指出 Expectiles 是 VaR 和 ES 风险度量的完全合理的替代方法,克服了 VaR 和 ES 的缺点,因此对极端损失大小也更为敏感。

给定概率水平 τ ,令 y 是某一资产组合收益率的随机变量,则 y 的 τ -Expectile 被定义为

$$e_\tau = \arg \min_{r \in R} E[\tau - I(y \leq r) | (y-r)^2] \quad (1)$$

式中: τ 为确定损失函数的不对称程度; e_τ 为 y 的第 τ 个 Expectile 估计值; $I(\cdot)$ 为示性函数。

给定 $X=x$ 的条件下, y 的条件 τ -Expectile 值可以由式(2)给定。

$$e_\tau(x) = \arg \min_e E\{\varphi(y, e | \tau) | X=x\} \quad (2)$$

1.2 Expectile 回归树模型

Expectile 回归树(expectile regression tree, ERT)模型通过不断二分递归构建二叉树,将数据集划分成不同的子集,在每个叶节点上估计目标变量的特定分位数,选择最优划分方式,以最小化目标变量的非对称平方损失函数。根据 Yang 和 Zou^[42] 的算法,估计每个叶节点上输出因变量的 τ 条件 Expectile 值,ERT 模型的求解步骤如下。

第一步: 设有一个升序排列的序列 $\{y_{(s)}\}_1^S$, 令 $y_{(0)} = -\infty, y_{(S+1)} = +\infty, S$ 为样本量。

第二步: $\varphi(\cdot | \omega)$ 作为 β 的函数,连续可微且严格凸,对于 $k=1, 2, \dots, S$ 有 $\beta \in [y_{(k)}, y_{(k+1)}]$, 则

$$\frac{\partial}{\partial \beta} \sum_{s=1}^S \varphi(y_{(s)}, \beta | \omega) \Big|_{\beta=\beta_k} = \frac{\partial}{\partial \beta} \left\{ \sum_{s=1}^S [(1-\omega) \times I(s \leq k) + \omega I(s \geq k+1)] (y_{(s)} - \beta)^2 \right\} \Big|_{\beta=\beta_k} = 0 \quad (3)$$

从而有

$$\beta_k = \frac{\sum_{s=1}^S (1-\omega) y_{(s)} I(s \leq k) + \omega y_{(s)} I(s \geq k+1)}{\sum_{s=1}^S (1-\omega) I(s \leq k) + \omega I(s \geq k+1)} \quad (4)$$

第三步: 对于 $k=1, 2, \dots, S$, 寻找唯一的 k^* 使得

$$y^{(k^*)} \leq \hat{\beta}_{k^*} \leq y^{(k^*+1)} \quad (5)$$

式中: $\hat{\beta}_{k^*}$ 为叶节点 R_l 上的 Expectile 估计值 $\hat{\text{Exp}}_y(\omega | x_i \in R_l)$ 。

1.3 Expectile 回归森林模型

借鉴 Cai 等^[40] 提出的基于 Bagging 方法和决策树相结合的随机森林集成方法构建 Expectile 回归森林(ERF)模型,其基本思想为:首先使用 Bagging 法构建多棵决策树,其次获得每棵决策树的条件期望预测值,最后将每棵决策树的结果取均值,得到 ERF 模型的条件期望预测值。在该模型中有 3 个核心参数,即 ntree(树的数量)、mtry(在每次分割时作为候选随机采样的变量的数量)、nodesize(决策树每个节点中的最小观察数)需要调整。对于给定的 (ntree, mtry, nodesize), 首先设置各参数的取值范围 $\text{ntree} \in \{50, 100, \dots, 1500\}, \text{mtry} \in \{1, 2, \dots, \text{ncol}(X)\}, \text{nodesize} \in \{2, 3, \dots, 15\}$, 然后通过最小袋外(OOB)样本的均方误差(MSE)来寻找最优参数,即使用式(6)来确定各参数最优值。

$$(\text{ntree}^*, \text{mtry}^*, \text{nodesize}^*) = \arg \min_{n, m, s} \frac{1}{n} \sum_{I \in \text{ob}} [y - \hat{\text{Exp}}_y(\omega | x_i)]^2 \quad (6)$$

根据基本思想,ERF 模型的具体算法:第一步,在数据集 $D = \{X_i, Y_i\}_{i=1}^n$ 中生成 G 棵决策树 $T(\gamma^g)$, $g=1, 2, \dots, G$, 由 L 个叶节点组成。其中, $\gamma^g = \{L_m^g, Y_m^g\}_{m=1}^M$ 为决策参数; L_m^g 为第 m 个叶节点; Y_m^g 为第 m 个叶节点的观测值,即 $Y_m^g = \{Y | X_i \in L_m^g\}, m=1, 2, \dots, M$ 。第二步,遍历所有决策树并计算每棵树在测试集数据 $te \in L_m^g$ 条件下的条件 Expectile 预测值。第三步,通过简单平均将条件期望值合并到每个决策树中,并用式(7)计算 ERF 模型的条件 Expectile 与测试值。

$$\hat{\text{Exp}}_y(\omega | te) = \frac{1}{G} \sum_{g=1}^G \hat{\text{Exp}}_y(\omega | te \in L_m^g) \quad (7)$$

2 实证结果与分析

2.1 样本选取与变量说明

2.1.1 样本选择

商业银行是银行业金融风险的主要贡献者^[43],选取 16 家 A 股上市的商业银行为研究对象,其中包含 5 家全国性大型商业银行,即工商银行、建设银行、中国银行、农业银行、交通银行;8 家股份制商业银行,即招商银行、浦发银行、民生银行、兴业银行、平安银行、中信银行、光大银行、华夏银行;3 家地方性城市商业银行,即南京银行、宁波银行、北京银行。时间跨度为 2013 年 1 月至 2022 年 12 月,上述数据均来自于 Wind 数据库。同时基于数据适配性的考虑,采用线性插值法将季度数据转化为月度数据^[44]。

选择上述样本原因在于:一方面,上市商业银行数据较非上市商业银行更易获取且更准确有效,可使研究结果更为可靠,加之各银行上市时间存在差异,考虑样本数据充足与完整,最终选取上述 16 家商业银行。另一方面,2008 年前上市的商业银行较少,样本量补充不足,且该期间包含 2008 年影响巨大的全球金融危机、2013 年中国银行同业拆借爆发的“钱荒”事件、2015 年“股灾”及 2020 年新冠肺炎疫情等主要极端事件,来预测全球金融危机结束后 10 余年中国商业银行金融风险现状,具有较好的研究代表性。

2.1.2 商业银行收益率

风险度量本质在于测度金融机构潜在的损失大小,考虑上市银行股票损益与风险因素之间的关系,选取 16 家 A 股上市商业银行的月度收盘价 P_t ,并根据收盘价计算收益率 y_t 。

$$y_t = \ln \frac{P_t}{P_{t-1}} \times 100 \quad (8)$$

2.1.3 风险影响因素的变量

(1) 银行杠杆率。范小云等^[45]发现非危机时期具有高杠杆率的金融机构在危机时期对整个金融系统的边际风险贡献较大,进一步发现杠杆率会刺激银行风险的发展,并且伴随银行风险水平的增加,杠杆率对其激励效应也增强^[30]。因此,在银行风险预测中考虑杠杆率因素是必要的。

在测度风险衡量杠杆率时更关注整个银行体系的收益和损失能力,所以本文采用商业银行一级资本净额与商业银行调整后的表内外资产余额的比率衡量^[31-32],记为 lev 。

(2) 银行规模。“太大而不能倒”的传统观念根深蒂固于银行业,这暗含大型银行往往偏好于高风

险投资,由此面临更大的风险隐患,而政策当局往往会对该类大型银行提供显性或隐性补助,以避免发生极端风险事件^[46]。Brownlees 和 Engle^[47]指出,杠杆率、规模和互联紧密性是金融风险最重要的决定因素,Benoit 等^[48]在研究风险来源时也得出一致结论。较早期的研究便发现,银行金融风险会随着银行资产规模的增加而增长^[34-35],而最新研究表明银行规模对风险的影响呈 U 形曲线^[49]。鉴于此,考虑银行规模对商业银行尾部风险的贡献程度显得十分必要。

参考 Laeven 等^[50]的做法,采用银行资产总额价值的自然对数度量银行规模,记为 $lnsize$ 。

(3) 经济政策不确定性。经济政策不确定性(EPU)已成为金融风险传染的重要驱动因素之一。一方面,后危机时代,国际金融市场持续动荡,经济政策不确定性不断攀升使得风险传染愈加频繁激烈,并且相关研究证据表明,当 EPU 增加时,银行很可能会加剧系统性风险^[32-34]。另一方面,Duan 等^[51]研究 EPU 跨国传播所带来的金融风险,发现发达国家是不确定性的净输出国,而发展中国家则是净输入国。此外,杨子暉等^[52]在探究 EPU 与金融风险的跨市场传染时,发现境外金融市场对大陆金融市场会产生显著的风险传染。因此,中国作为最大的发展中国家,而银行是经济体系的核心部分,在测度中国商业银行收益率风险时纳入经济政策不确定性的考虑是必然的。

由于美国作为世界第一大经济体,是经济政策不确定性主要输出国之一;中国作为最大发展中国家,是经济政策不确定性主要输入国之一,因此本文选取美国和中国的 EPU 指数(分别记为 $usepu$ 、 $chepu$)便具有一定的代表性和说服力。该指数来源于 Baker 根据报纸报道设计的 EPU 指数:<https://www.policyuncertainty.com>^[53]。

(4) 金融市场的波动性与流动性。金融市场的波动性与流动性是金融体系产生金融风险的内在原因,何青等^[54]在此基础上构造出包含金融市场波动性和流动性因素的金融风险指数,发现该指数能有效预测未来宏观经济冲击的分布情形。伴随金融全球化步伐的加快和金融市场之间联系的逐步加强,金融市场的波动溢出效应及其流动性更加值得关注;Sun 和 Chen^[55]指出危机事件的冲击会增强全球金融市场波动溢出效应;Chen 等^[56]证实了金融市场的流动性是金融风险的关键贡献之一,具有引起全球系统传染的巨大潜力。鉴于此,本文考

虑金融市场的波动性和流动性的影响,对于防范和管理商业银行尾部风险及其重要。

由于沪深 300 指数由上海和深圳两个证券交易所联合发布,且每年调整一次股票标的,其分布状况与中国市场和行业的分布比例基本一致,具有较高的代表性和稳定性。因此,选用沪深 300 指数的日收益率月度标准差衡量波动性(记为 vol);参考 Amihud^[57] 和张宗新等^[58] 的做法,并取对数,则流动性水平定义如式(9)所示(记为 lnliq)。

$$\lnliq = \ln \frac{\text{vol}_{imt}}{|r_{i,m,t}|} \quad (9)$$

式中: vol_{imt} 为股票 i 在 t 年 m 月 0 的成交额; |r_{i,m,t}| 为股票 i 在 t 年 m 月的收益率的绝对值。

2.2 实证过程

2.2.1 描述性统计

分析每家商业银行月收益率的描述性统计特征,结果如表 1 所示。从表 1 可知,所选取的每一家商业银行的偏度都异于 0,峰度均大于 3,表明各银行的收益率具有尖峰厚尾的特征,且 JB 统计量的 P 均小于 0.01,即非正态分布。同时 ADF 检验的 P 表明该收益率序列是平稳时间序列。

2.2.2 预测结果比较

根据每组样本数据按照训练集:测试集 = 2:1 的标准随机抽取数据分别作为训练集数据和测试集数据。首先,分别在 τ 取 0.25、0.5、0.75 时对训练集数据拟合 ERF、ERT、ER 模型;其次,利用测试集数据进行预测;最后,分别计算训练集和测试集的平均绝对误差(MAE)和均方根误差(RMSE),以评价不同模型估计和预测能力的优劣。其中,MAE 和 RMSE 计算公式分别为

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i(\tau|x_i)| \quad (10)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n [y_i - \hat{y}_i(\tau|x_i)]^2} \quad (11)$$

表 2 报告样本数据训练集和测试集在 ERF、ERT、ER 模型下真实值与预测值的 MAE 和 RMSE 结果。可以看出,无论是测试集还是训练集,每个银行在不同谨慎性水平 τ 下,ERF 模型的预测误差及其标准差都是 ERF、ERT、ER 三个模型中的最小值,这表明 ERF 模型相较于传统的期望分位数回归而言具有较高的估计和预测精度。同时,从表 2 中还可看出,每个模型在水平 0.5 时的误差及标准差值均小于其他水平,这是因为当 τ 取 0.5 时,分位数回归与均值回归等价。

将上述各银行进行分类,并计算各类商行在不同水平以及不同模型下的 RMSE 及其标准差的均值。表 3 结果显示,不论是训练集还是测试集,全国性大型商业银行、股份制商行及地方性城市商业银行在 ERF 模型下的误差值均小于 ERT 和 ER 模型的误差值,表明 ERF 模型的估计预测能力优于另外两个模型。同时,全国性大型商业银行的估计误差和预测误差均小于股份制商业银行和地方性城市商业银行,可能原因在于全国性大型商业银行是由国家控股的银行,其所有权和经营决策都由政府掌控,相较于其他类型银行而言,受到重点或重大国家项目的支持力度更大,其经营更为稳定,风险更小,从而风险预测误差会偏小。

2.3 稳健性检验

为进一步增强上述结果的可靠性,主要通过以

表 1 上市商业银行收益率描述性统计

银行名称	均值	标准差	偏度	峰度	Jaque-Bera	ADF
工商银行	0.037 3	5.241 8	0.364 1	4.807 8	18.992*** (0.000 0)	-11.112*** (0.000 0)
建设银行	0.168 4	7.146 3	0.774 5	7.959 9	134.999*** (0.000 0)	-11.741*** (0.000 0)
中国银行	0.065 8	5.403 4	0.224 5	7.240 1	90.902*** (0.000 0)	-9.844*** (0.000 0)
农业银行	0.032 1	5.014 8	1.115 0	9.047 6	207.729*** (0.000 0)	-10.650*** (0.000 0)
交通银行	-0.034 4	6.159 7	0.510 2	6.413 6	63.471*** (0.000 0)	-11.096*** (0.000 0)
招商银行	0.830 7	8.197 4	0.227 1	4.828 5	17.749*** (0.000 1)	-11.669*** (0.000 0)
浦发银行	-0.257 9	7.003 7	0.231 8	4.420 6	11.165*** (0.003 8)	-10.865*** (0.000 0)
民生银行	-0.686 2	7.069 9	1.732 5	12.448 1	506.368*** (0.000 0)	-11.454*** (0.000 0)
兴业银行	0.043 8	9.214 4	-0.877 8	9.485 0	225.688*** (0.000 0)	-10.580*** (0.000 0)
平安银行	-0.163 9	11.623 9	-2.035 6	15.504 7	864.715*** (0.000 0)	-11.126*** (0.000 0)
中信银行	0.124 3	8.279 3	0.955 7	7.356 8	113.178*** (0.000 0)	-11.925*** (0.000 0)
光大银行	0.005 4	6.776 7	0.661 7	5.240 7	33.859*** (0.000 0)	-10.099*** (0.000 0)
华夏银行	-0.575 2	7.943 8	-0.891 0	9.141 0	204.445*** (0.000 0)	-10.758*** (0.000 0)
南京银行	0.103 8	10.800 7	-1.962 9	13.263 1	603.710*** (0.000 0)	-11.986*** (0.000 0)
宁波银行	0.927 7	9.954 0	-1.154 3	7.563 8	130.791*** (0.000 0)	-11.775*** (0.000 0)
北京银行	-0.640 9	6.938 9	-1.763 9	12.735 4	536.112*** (0.000 0)	-12.126*** (0.000 0)

注:***、**、*分别表示 Jaque-Bera、ADF 检验统计量在 1%、5%、10%的水平下显著;括号内是相应的 P 值。

表 2 样本数据在不同模型的 MAE 和 RMSE 结果

数据集	τ	RMSE 结果						MAE 结果					
		ERF		ERT		ER		ERF		ERT		ER	
		训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
工商银行	0.25	3.608 1	3.942 1	5.266 9	4.464 9	4.629 1	5.966 0	2.703 5	2.818 4	4.079 7	3.253 1	3.493 3	4.332 1
	0.50	3.048 6	3.011 6	4.855 9	4.126 5	4.266 6	5.433 0	2.344 7	2.290 9	3.603 1	3.173 6	3.136 3	4.096 2
	0.75	3.492 1	3.724 7	5.250 1	4.563 8	4.674 7	5.966 5	2.693 3	2.792 4	3.991 8	3.681 1	3.690 0	4.401 8
建设银行	0.25	5.908 8	5.929 2	6.438 2	6.212 5	7.485 5	6.471 0	3.890 6	4.802 0	4.841 7	5.078 0	4.947 1	4.836 7
	0.50	5.098 6	4.934 3	5.893 6	5.636 8	7.006 1	5.822 6	3.642 6	3.877 4	4.575 0	4.349 1	4.850 7	4.433 5
	0.75	5.696 5	5.488 2	6.473 3	6.076 9	7.708 2	6.414 4	4.376 1	4.070 5	4.917 7	4.521 4	5.774 5	4.599 7
中国银行	0.25	3.274 7	4.269 8	4.538 0	5.242 7	4.763 1	5.338 8	2.468 5	2.764 3	3.412 8	3.717 1	3.535 2	3.985 1
	0.50	2.807 0	3.366 4	4.133 4	4.831 7	4.359 0	4.839 3	2.079 6	2.390 3	2.968 6	3.278 2	3.280 6	3.666 0
	0.75	3.416 0	3.872 8	4.466 1	5.343 6	4.797 5	5.325 1	2.574 6	2.861 3	3.185 9	3.929 6	3.550 0	4.108 8
农业银行	0.25	3.126 0	4.201 0	4.669 0	5.208 5	4.181 6	5.322 1	2.322 7	2.722 6	3.755 6	3.495 9	3.198 1	3.675 5
	0.50	2.689 8	3.136 9	4.274 7	4.822 0	3.836 1	4.945 4	2.039 3	2.152 9	3.148 7	3.264 4	2.972 7	3.540 3
	0.75	3.159 7	3.442 7	4.574 0	5.283 2	4.190 5	5.496 4	2.419 7	2.435 5	3.254 9	3.665 4	3.254 3	4.152 3
交通银行	0.25	3.747 8	3.673 3	6.067 4	5.637 6	5.144 5	5.485 1	3.215 1	2.758 7	4.651 4	4.213 2	3.826 8	4.769 5
	0.50	3.119 3	2.593 6	5.604 0	5.126 5	4.769 2	4.951 2	2.810 7	2.174 5	4.010 2	3.849 7	3.429 9	4.535 3
	0.75	3.809 0	3.628 9	5.987 9	5.671 5	5.156 7	5.459 1	3.136 8	2.817 1	4.219 0	4.176 8	3.847 8	5.027 6
招商银行	0.25	7.326 0	5.855 0	8.259 6	6.200 4	9.090 0	6.238 5	5.231 1	4.173 3	5.368 4	5.180 3	6.588 3	5.061 0
	0.50	6.513 2	5.247 6	7.641 0	5.597 1	8.372 3	5.595 7	4.718 6	3.580 6	4.932 3	4.450 5	6.062 6	4.262 9
	0.75	7.288 3	5.939 6	8.349 5	6.038 3	9.150 9	6.056 7	5.352 4	4.242 5	5.532 9	4.519 8	6.711 2	4.478 8
浦发银行	0.25	5.372 9	7.100 0	5.961 3	7.581 4	6.787 6	7.541 5	4.143 4	5.423 0	4.344 7	6.036 0	5.155 2	5.739 3
	0.50	4.732 7	6.018 4	5.493 4	6.889 6	6.201 0	6.918 4	3.727 7	4.736 0	3.991 4	5.281 7	4.700 2	5.294 5
	0.75	5.529 5	6.761 1	6.020 9	7.560 1	6.787 7	7.629 9	4.331 1	5.274 5	4.575 7	5.735 5	5.170 6	6.066 0
民生银行	0.25	4.478 6	8.035 7	4.962 7	8.353 3	5.668 8	9.196 2	3.517 3	4.799 0	3.769 9	2.364 8	4.292 2	5.360 3
	0.50	3.995 2	7.025 1	4.502 9	7.784 9	5.183 2	8.640 5	2.054 3	4.230 2	3.221 1	5.189 6	3.814 8	5.341 6
	0.75	4.673 0	7.568 5	4.886 8	8.635 4	5.624 3	9.689 6	3.366 5	5.304 5	3.479 4	6.100 2	4.172 7	6.843 7
兴业银行	0.25	6.979 7	6.989 4	8.636 4	8.595 4	8.902 1	8.808 4	5.282 8	4.970 7	6.609 2	6.036 1	6.793 3	6.411 8
	0.50	6.394 4	5.846 8	7.864 2	8.029 0	8.134 4	8.001 3	4.563 9	4.294 2	5.550 7	5.856 5	5.959 8	5.763 4
	0.75	7.574 7	7.075 7	8.427 6	8.798 0	8.734 7	8.783 1	5.078 6	5.275 7	5.891 7	6.946 1	6.148 0	6.129 6
平安银行	0.25	9.120 4	5.864 3	11.840 1	9.323 3	12.649 6	8.597 3	7.130 2	6.200 8	8.577 9	7.418 2	9.432 3	6.406 0
	0.50	8.332 4	4.474 4	10.781 2	8.439 1	11.528 3	7.830 0	6.044 3	5.313 1	7.082 7	6.370 3	7.929 6	5.901 0
	0.75	10.095 2	5.981 5	11.508 1	9.113 3	12.371 2	8.605 1	6.695 4	5.775 4	7.352 3	6.558 3	8.279 5	6.436 0
中信银行	0.25	7.047 3	7.160 2	7.182 5	8.348 7	8.183 3	8.678 8	4.782 2	4.765 7	4.945 8	5.931 9	5.486 1	5.650 2
	0.50	6.067 8	6.396 7	6.656 1	7.783 5	7.652 2	8.011 1	4.185 3	4.363 7	4.591 9	5.375 7	5.361 6	5.376 6
	0.75	6.493 7	7.246 2	7.287 7	8.473 6	8.348 3	8.918 1	4.789 8	5.213 3	5.244 3	6.131 3	6.248 1	6.133 5
光大银行	0.25	4.317 9	5.510 1	6.071 4	7.158 6	5.232 8	8.193 3	3.338 5	3.964 0	4.859 1	5.029 1	4.066 6	6.094 3
	0.50	3.641 7	4.305 3	5.564 1	6.629 5	4.761 4	7.465 9	2.817 5	3.304 6	4.282 6	4.998 6	3.634 1	5.760 7
	0.75	4.233 2	5.419 8	6.018 9	7.359 8	5.203 6	8.265 1	3.256 6	3.992 4	4.590 5	5.650 1	3.966 3	6.219 6
华夏银行	0.25	5.774 2	4.534 2	7.604 0	6.154 6	7.674 5	7.229 8	4.240 9	2.805 3	5.546 0	3.873 9	5.865 0	4.888 4
	0.50	5.102 3	3.124 6	6.824 4	5.706 6	6.944 8	6.707 2	3.387 9	2.247 7	4.674 7	3.722 8	5.037 2	4.924 2
	0.75	6.268 3	3.900 9	7.316 8	6.350 9	7.498 2	7.498 4	3.976 3	2.849 5	4.675 0	4.456 1	5.189 9	5.732 4
南京银行	0.25	7.131 7	11.498 3	7.231 6	14.437 0	8.564 1	14.782 8	5.259 9	8.911 6	5.275 8	11.455 5	6.382 7	11.492 1
	0.50	6.241 4	11.499 2	6.668 0	13.097 8	7.882 0	13.071 4	4.670 8	7.060 0	4.787 3	8.005 4	6.138 0	9.053 8
	0.75	7.151 8	13.221 1	7.261 2	13.711 5	8.685 6	14.069 0	5.294 8	7.584 8	5.786 3	7.888 6	6.998 4	8.386 6
宁波银行	0.25	6.206 9	4.872 9	9.099 2	7.070 0	9.194 8	8.604 6	4.794 9	4.127 2	6.888 2	5.584 7	7.042 8	7.567 6
	0.50	5.274 7	4.259 9	8.284 1	6.354 7	8.427 0	7.683 4	4.019 4	3.059 7	5.837 0	4.262 7	6.420 3	6.141 3
	0.75	6.728 7	5.706 3	8.954 1	6.750 0	9.156 9	8.245 2	4.686 2	3.494 4	6.298 7	4.448 0	6.787 4	5.766 2
北京银行	0.25	4.084 4	7.505 0	4.245 3	8.989 1	5.438 2	9.700 2	3.122 1	6.008 1	3.134 9	6.416 7	4.130 8	7.249 9
	0.50	3.561 4	6.572 7	3.903 7	8.135 9	4.963 5	8.666 5	2.731 0	4.538 5	2.847 9	5.572 0	3.767 3	6.086 3
	0.75	4.207 9	7.824 2	4.283 1	8.763 6	5.439 1	9.361 0	3.135 2	4.627 2	3.234 1	5.907 9	4.044 3	5.950 8

注:加粗为最小者。

下三种方式对模型进行稳健性检验:①改变样本数据训练集与测试集的比例,将样本数据按照 60%随机抽取数据作为训练集,剩下的 40%数据

作为测试集,重新进行预测;②更换解释变量,将度量金融市场的波动性和流动性指标分别替换为沪深 300 指数的 GARCH 波动率^[59]和换手率^[28];

③对样本数据做上下 5%缩尾处理。稳健性检验 三者中最小,估计和预测能力不变,表明该风险预测结果如表 4 所示。结果发现 ERF 模型的误差仍是 测模型较为稳健。

表 3 各类型商业银行在不同模型的预测结果比较

评价指标	银行类型	τ	ERF		ERT		ER	
			训练集	测试集	训练集	测试集	训练集	测试集
RMSE	全国性大型 商业银行	0.25	3.933 1	4.403 1	5.395 9	5.353 2	5.240 8	5.716 6
		0.50	3.352 7	3.408 6	4.952 3	4.908 7	4.847 4	5.198 3
		0.75	3.914 7	4.031 5	5.350 3	5.387 8	5.305 5	5.732 3
	股份制 商业银行	0.25	6.302 1	6.381 1	7.564 8	7.714 5	8.023 6	8.060 5
		0.50	5.597 5	5.304 9	6.915 9	7.107 4	7.346 6	7.396 3
		0.75	6.519 5	6.236 7	7.477 0	7.791 2	7.964 9	8.180 8
	地方性城市 商业银行	0.25	5.807 7	7.958 7	6.858 7	10.165 4	7.732 4	11.029 2
		0.50	5.025 8	7.443 9	6.285 3	9.196 1	7.090 8	9.807 1
		0.75	6.029 5	8.917 2	6.832 8	9.741 7	7.760 5	10.558 4
MAE	全国性大型 商业银行	0.25	2.920 1	3.173 2	4.148 2	3.951 5	3.800 1	4.319 8
		0.50	2.583 4	2.577 2	3.661 1	3.583 0	3.534 0	4.054 3
		0.75	3.040 1	2.995 4	3.913 9	3.994 9	4.023 3	4.458 0
	股份制 商业银行	0.25	4.708 3	4.637 7	5.502 6	5.608 8	5.959 9	5.701 4
		0.50	4.062 4	4.008 8	4.790 9	5.155 7	5.312 5	5.328 1
		0.75	4.605 8	4.741 0	5.167 7	5.762 2	5.735 8	6.005 0
	地方性城市 商业银行	0.25	4.392 3	6.349 0	5.099 6	7.819 0	5.852 1	8.769 9
		0.50	3.807 1	4.886 1	4.490 7	5.946 7	5.441 9	7.093 8
		0.75	4.372 1	5.235 5	5.106 4	6.081 5	5.943 4	6.701 2

表 4 稳健性结果

银行类型	替换对象	τ	ERF		ERT		ER	
			训练集	测试集	训练集	测试集	训练集	测试集
全国性大型 商业银行	训练集: 测试集= 3:2	0.25	4.562 3	4.175 0	5.402 0	4.769 2	6.024 2	5.442 4
		0.50	3.979 6	3.521 8	4.973 3	4.337 5	5.370 5	4.949 7
		0.75	3.794 3	4.308 0	4.876 0	4.732 2	5.605 1	5.447 5
	更改 自变量	0.25	4.241 0	4.225 7	5.416 8	5.563 9	5.643 4	5.464 4
		0.50	3.550 2	3.337 9	4.971 5	5.112 6	5.150 0	4.901 0
		0.75	4.098 2	4.019 2	5.366 4	5.596 4	5.596 7	5.326 9
	上下 5% 缩尾	0.25	3.394 1	3.794 4	4.293 5	4.380 1	4.379 2	4.570 2
		0.50	2.863 5	3.327 8	3.903 4	3.962 7	3.999 0	4.117 5
		0.75	3.396 6	3.938 6	4.258 2	4.312 4	4.405 7	4.512 2
股份制 商业银行	训练集: 测试集= 3:2	0.25	6.191 1	6.315 6	7.913 3	8.598 1	7.689 6	9.200 1
		0.50	5.420 1	5.289 8	7.323 9	7.928 6	7.069 8	8.466 3
		0.75	6.203 4	6.367 3	7.550 3	8.555 5	7.730 0	9.214 5
	更改 自变量	0.25	6.229 4	6.265 3	7.574 6	7.607 6	8.169 4	7.514 4
		0.50	5.502 5	5.240 2	6.890 6	7.018 1	7.534 2	6.812 7
		0.75	6.405 8	6.074 1	7.423 6	7.677 5	8.079 3	7.422 2
	上下 5%缩尾	0.25	5.420 1	5.254 2	5.836 4	5.800 9	6.440 2	6.067 0
		0.50	4.693 1	4.412 7	5.318 0	5.271 1	5.869 9	5.475 8
		0.75	5.473 6	5.164 8	5.821 8	5.742 5	6.456 1	6.015 5
地方性城市 商业银行	训练集: 测试集= 3:2	0.25	5.855 9	8.501 0	8.501 1	11.003 0	7.987 6	10.951 2
		0.50	5.018 4	8.069 4	7.841 4	10.032 5	7.321 4	9.857 2
		0.75	6.062 1	9.400 0	8.460 0	10.616 1	8.033 9	10.667 0
	更改 自变量	0.25	5.811 1	7.632 5	6.718 7	103.526	8.236 0	11.007 5
		0.50	5.161 5	7.432 3	6.097 1	9.375 8	7.496 6	9.706 0
		0.75	6.244 9	9.060 0	6.662 7	9.939 1	8.171 1	10.357 6
	上下 5%缩尾	0.25	5.465 4	5.725 1	5.891 7	6.190 4	6.699 9	6.904 1
		0.50	4.707 9	4.992 2	5.387 9	5.631 9	6.102 1	6.159 8
		0.75	5.592 1	5.764 3	5.910 5	6.115 4	6.708 5	6.696 5

注:此表展示 RMSE 结果。

2.4 进一步讨论

全国性大型商业银行、股份制商业银行及部分地方性城市商业银行都更早于地方性农村商业银行改制与上市时间,在运营、管理、风控等各方面都更为成熟稳定,所以对地方性农村商业银行测度其尾部风险更具实际意义。考虑到最早一批上市的地方性农商行时间为 2016 年 9 月,为尽可能使样本量更多一些,选择江阴银行、无锡银行、常熟银行和苏农银行 4 家地方性农村商业银行,时间跨度为 2016 年 12 月至 2023 年 6 月。

将样本地方性农商行在不同模型下的 RMSE 及标准差求均值并汇总于表 5,结果显示,在训练集和测试集中,ERF 模型估计及预测下的 RMSE 和标准差均小于 ERT 和 ER 模型,与上述结论一致。并且也通过了稳健性检验(表 6),再次说明 ERF 模型具有较好的预测性能。

但对比全国性大型商业银行、股份制商业银行和地方性城市商业银行,无论是在不同模型还是不同风险水平下地方性农商行的预测误差都更大一些。出现这种差异的可能原因在于:①内在原因。一方面,中国农村商业银行股权结构复杂,内部控制问题严重,表现为股东持股分散,大股东持股比例较低,并且出现股东入股后无视监管规则,越位现象严重;另一方面,追求规模“大而不倒”的发展战略,过度扩张跨区经验导致部分农商行资金配置

效率降低,积累了大量风险。此外,由于存在城乡差距,农商行在自身经营、内部管理、风险控制与监督等方面仍相对薄弱,这可能进一步放大了风险^[60]。②外部环境。一方面,政府在银行改革体系进程不平衡,地方性农村商业银行改制相对滞后于地方性城市商业银行,并且地方性农村商业银行在获得政府扶持上也存在差距,这可能会使农商行在技术、人员培训等投入不足;同时由于信息更新不及时,难以获取更全面、准确的数据,这对风险预测的精准性也会造成一定影响。另一方面,在鼓励创新和规范金融发展过程中,农商行监管和政策协调不够充分,使得部分银行在经营和转型方面面临较大困难,这些问题可能导致风险预测和管理上存在漏洞,从而增加了误差的可能性。

3 结论

本文构建了包含杠杆率、资产规模、经济政策不确定、金融市场波动性和流动性 5 个金融变量的上市商业银行风险预测模型——Expectile 回归森林(ERF)模型,对在 A 股上市的商业银行的进行尾部风险测度,并将测度结果与传统的期望分位数回归(ER)模型、期望分位数回归树(ERT)模型的测度结果比较。通过实证检验得出以下结论:第一,ERF 模型在测度中国上市商业银行尾部风险具有可行性;第二,对于全国性大型商业银行、股份制商业银

表 5 地方性农商行在不同模型下的误差结果

评价指标	银行类型	τ	ERF		ERT		ER	
			训练集	测试集	训练集	测试集	训练集	测试集
RMSE	地方性农村商业银行	0.25	8.769 3	7.937 9	8.807 1	10.003 6	10.910 4	9.172 7
		0.50	7.522 2	7.095 4	8.181 3	9.179 8	10.185 6	8.375 0
		0.75	8.253 5	8.105 6	8.978 3	9.865 9	11.164 0	9.241 1
MAE	地方性农村商业银行	0.25	3.665 6	4.748 4	3.869 9	6.294 5	4.919 0	5.502 3
		0.50	3.208 2	4.153 2	3.704 2	5.279 3	4.789 1	4.783 9
		0.75	3.877 6	4.607 6	4.417 9	5.515 3	5.596 2	5.177 3

表 6 地方性农商行稳健性检验结果

τ	更改对象	ERF		ERT		ER	
		训练集	测试集	训练集	测试集	训练集	测试集
0.25	训练集:测试集=3:2	8.652 9	6.490 8	9.646 9	9.504 6	11.073 5	8.603 5
	更改自变量	8.575 0	7.164 2	9.056 9	10.003 6	10.406 4	8.337 8
	上下 5%缩尾	6.396 6	6.737 1	6.781 5	8.377 4	7.743 9	7.481 2
0.50	训练集:测试集=3:2	7.271 9	5.630 5	9.160 5	8.739 8	10.349 6	7.917 6
	更改自变量	7.422 9	6.135 6	8.482 9	9.179 8	9.746 1	8.337 8
	上下 5%缩尾	5.446 1	5.763 7	6.228 5	7.606 7	7.129 0	6.830 8
0.75	训练集:测试集=3:2	8.195 8	6.728 4	9.887 1	9.432 6	11.364 4	8.749 7
	更改自变量	8.194 9	7.083 9	9.212 7	9.865 9	10.660 3	8.458 5
	上下 5%缩尾	6.266 8	6.668 1	6.865 8	8.263 0	7.918 8	7.549 8

注:此表展示 RMSE 结果。

行、地方性城市商业银行及地方性农村商业银行四类商业银行的尾部风险测度,无论是样本内拟合还是样本外预测,ERF 模型的估计和预测精度都更优于 ERT 和 ER 模型,并通过稳健性检验;第三,四种类型商业银行中,全国性大型商业银行的预测误差值最小,而地方性农村商业银行误差值最大,股份制商业银行与地方性城市商业银行次之。

金融是“国之大者”,关系到中国式现代化建设全局,而商业银行对一国经济的重要性不言而喻。基于上述研究结论,提出:一是商业银行的风险管理要全面考虑变量所包含的信息开展金融尾部风险测度;二是金融监管者要分类分层对各类型商业银行风险进行管理,尤其是对地方性农村商业银行的金融风险更加重点监控。当然,本文研究也存在着不足之处,主要表现为只选取了部分银行特征(杠杆率和资产规模)、美国和中国经济政策不确定性指数、以沪深 300 指数为代表的金融市场波动性和流动性指标作为可能引发中国商业银行发生金融风险的变量。在后续进一步研究中,考虑将宏观或微观审慎,或者宏微观审慎同时纳入考虑,以及跨国、跨市场间的风险传染对中国商业银行风险的影响等因素,建立更加科学全面综合的我国商业银行尾部风险预测模型并检验其测度效能。

参考文献

- [1] YADAV M P, RAO A, ABEDIN M Z, et al. The domino effect: analyzing the impact of silicon valley bank's fall on top equity indices around the world[J]. *Finance Research Letters*, 2023, 55: 103952.
- [2] PANDEY D K, HASSAN M K, KUMARI V, et al. Repercussions of the silicon valley bank collapse on global stock markets [J]. *Finance Research Letters*, 2023, 55: 104013.
- [3] 熊启跃, 吕昊旻, 初晓, 等. 美国硅谷银行倒闭的影响及启示[J]. *国际金融*, 2023(4): 57-66.
- [4] 王家强, 高妍. 美国硅谷银行倒闭成因、系统性风险前景及政策启示[J]. *清华金融评论*, 2023(4): 63-67.
- [5] 尹豪. 系统性金融风险度量研究综述[J]. *金融监管研究*, 2020(12): 32-49.
- [6] 杨子晖, 陈雨恬, 林师涵. 系统性金融风险文献综述: 现状、发展与展望[J]. *金融研究*, 2022(1): 185-206.
- [7] ADRIAN T, BRUNNERMEIER M K. CoVaR[J]. *The American Economic Review*, 2016, 106(7): 1705-1741.
- [8] DE MENDONÇA H F, SILVA R B D. Effect of banking and macroeconomic variables on systemic risk: an application of Δ CoVaR for an emerging economy [J]. *North American Journal of Economics and Finance*, 2018, 43: 141-157.
- [9] HUANG Q B, DE HAAN J, SCHOLTEN B. Analysing systemic risk in the Chinese banking system[J]. *Pacific Economic Review*, 2019, 24(2): 348-372.
- [10] HAO X Z, CHEN Z L. Systemic risk in Chinese financial industries: a vine copula grouped CoVaR approach [J]. *Economic Research-Ekonomska Istraživanja*, 2022, 35(1): 2747-2763.
- [11] 陈守东, 王妍. 我国金融机构的系统性金融风险评估——基于极端分位数回归技术的风险度量[J]. *中国管理科学*, 2014, 22(7): 10-17.
- [12] 肖璞, 刘轶, 杨苏梅. 相互关联性、风险溢出与系统重要性银行识别[J]. *金融研究*, 2012(12): 96-106.
- [13] 杜子平, 李金. 基于 CoVaR 方法对中国系统重要性银行的实证研究——GARCH 模型和分位数回归方法的对比分析[J]. *金融与经济*, 2014(11): 11-16.
- [14] 高国华, 潘英丽. 银行系统性风险度量——基于动态 CoVaR 方法的分析[J]. *上海交通大学学报*, 2011, 45(12): 1753-1759.
- [15] ACHARYA V V, PEDERSEN L H, PHILIPPON T, et al. Measuring systemic risk [J]. *Review of Financial Studies*, 2017, 30(1): 20-47.
- [16] BROWNLEES C, ENGLE R F. SRISK: a conditional capital shortfall measure of systemic risk[J]. *Review of Financial Studies*, 2017, 30(1): 48-79.
- [17] 刘晓倩, 周勇. 金融风险度量中 ES 度量的非参数方法的比较及其应用[J]. *系统工程理论与实践*, 2011, 31(4): 631-642.
- [18] 刘吕科, 张定胜, 邹恒甫. 金融系统性风险衡量研究最新进展述评[J]. *金融研究*, 2012(11): 31-43.
- [19] 赵进文, 张胜保, 韦文彬. 系统性金融风险度量方法的比较与应用[J]. *统计研究*, 2013, 30(10): 46-53.
- [20] 宋清华, 姜玉东. 中国上市银行系统性风险度量——基于 MES 方法的分析[J]. *财经理论与实践*, 2014, 35(6): 2-7.
- [21] 张冰洁, 汪寿阳, 魏云捷, 等. 基于 CoES 模型的我国金融系统性风险度量[J]. *系统工程理论与实践*, 2018, 38(3): 565-575.
- [22] ARTZNER P, DELBAEN F, EBER J M, et al. Coherent measures of risk[J]. *Mathematical Finance*, 1999, 9(3): 203-228.
- [23] 苏辛, 谢尚宇, 周勇. 金融风险度量的建模理论与方法的一些进展及其应用[J]. *运筹与管理*, 2018, 27(1): 185-199.
- [24] NEWEY W K, POWELL J L. Asymmetric least squares estimation and testing [J]. *Econometrica*, 1987, 55(4): 819.
- [25] 严复雷, 张语桐, 崔钟月, 等. 基于非参多元 Expectile 模型的原油价格风险测度研究——宏观不确定性视角[J]. *中国管理科学*, 2022, 30(12): 222-233.
- [26] 胡宗义, 万闯, 李毅. 基于 Expectile 风险建模的原油价

- 格风险测度研究[J]. 统计与信息论坛, 2018, 33(1): 58-64.
- [27] 苏辛, 周勇. 条件自回归 Expectile 模型及其在基金业绩评价中的应用[J]. 中国管理科学, 2013, 21(6): 22-29.
- [28] 谢尚宇, 姚宏伟, 周勇. 基于 ARCH-Expectile 方法的 VaR 和 ES 尾部风险测量[J]. 中国管理科学, 2014, 22(9): 1-9.
- [29] 解其昌. 分位数回归方法及其在金融市场风险价值预测中的应用[D]. 成都: 西南财经大学, 2012.
- [30] 王妍, 陈守东. 尾部极值分布下的系统性金融风险度量及影响因素分析[J]. 数理统计与管理, 2014, 33(6): 1010-1020.
- [31] 张家臻, 刘亚. 中国银行业系统性风险的度量及影响因素研究[J]. 经济经纬, 2018, 35(5): 143-150.
- [32] 李洋, 佟孟华, 褚翠翠. 经济政策不确定性与系统性金融风险传染——基于中国上市金融机构微观数据的经验证据[J]. 金融经济研究, 2021, 36(4): 31-47.
- [33] 蒋海, 王溢凡, 吴文洋. 经济政策不确定性、网络关联性与银行业系统性风险——基于中国上市银行的实证检验[J]. 金融经济研究, 2021, 36(6): 3-17.
- [34] 顾海峰, 朱慧萍. 经济政策不确定性是否会影响银行系统性风险? [J]. 系统工程理论与实践, 2022, 42(9): 2350-2366.
- [35] 周爱民, 刘欣蕊. 经济政策不确定性、银行集中度与银行风险[J]. 经济理论与经济管理, 2021, 41(3): 10-25.
- [36] GIGLIO S, KELLY B, PRUITT S. Systemic risk and the macroeconomy: an empirical evaluation[J]. Journal of Financial Economics, 2016, 119(3): 451-471.
- [37] 郭宜淳, 贾骁骁, 马淑霞. 金融科技发展对商业银行风险承担的影响[J]. 科技和产业, 2024, 24(24): 94-102.
- [38] 李树凤. 履行社会责任对商业银行风险承担的影响——基于银行业竞争与绿色信贷的调节效应[J]. 科技和产业, 2024, 24(15): 105-109.
- [39] YAO Q, TONG H. Asymmetric least squares regression estimation: a nonparametric approach[J]. Journal of Nonparametric Statistics, 1996, 6(2/3): 273-292.
- [40] CAI C, DONG H T, WANG X Y. Expectile regression forest: a new nonparametric expectile regression model [J]. Expert Systems, 2022, 40(1): e13087.
- [41] BELLINI F, DI BERNARDINO E. Risk management with expectiles[J]. The European Journal of Finance, 2017, 23(6): 487-506.
- [42] YANG Y, ZOU H. Nonparametric multiple expectile regression via ER-Boost[J]. Journal of Statistical Computation and Simulation, 2015, 85(7): 1442-1458.
- [43] 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[J]. 经济研究, 2018, 53(8): 36-51.
- [44] 杨子晖, 戴志颖. 中国上下行风险的非对称溢出冲击研究——基于高频数据合成网络的分析[J]. 中国工业经济, 2023(3): 77-95.
- [45] 范小云, 王道平, 方意. 我国金融机构的系统性风险贡献测度与监管——基于边际风险贡献与杠杆率的研究[J]. 南开经济研究, 2011(4): 3-20.
- [46] 高嘉璘, 王雪标, 周鑫. 杠杆率对银行系统性风险的影响[J]. 统计与决策, 2021, 37(21): 150-153.
- [47] BROWNLEES C, ENGLE R F. SRISK: A conditional capital shortfall measure of systemic risk[J]. Review of Financial Studies, 2017, 30(1): 48-79.
- [48] BENOIT S, COLLIARD J E, HURLIN C, et al. Where the risks lie: a survey on systemic risk[J]. Review of Finance, 2017, 21(1): 109-152.
- [49] BENBOUZID N, LEONIDA L, MALLICK S K. The non-monotonic impact of bank size on their default swap spreads: cross-country evidence [J]. International Review of Financial Analysis, 2018, 55: 226-240.
- [50] LAEVEN L, RATNOVSKI L, TONG H. Bank size, capital and systemic risk: some international evidence [J]. Journal of Banking and Finance, 2016, 69: S25-S34.
- [51] DUAN Y J, FAN X Y, WANG Y. Economic policy uncertainty and bank systemic risk: a cross-country analysis [J]. Pacific-Basin Finance Journal, 2022, 75: 101828.
- [52] 杨子晖, 陈里璇, 陈雨恬. 经济政策不确定性与系统性金融风险的跨市场传染——基于非线性网络关联的研究[J]. 经济研究, 2020, 55(1): 65-81.
- [53] BAKER S R, BLOOM N, DAVIS S J. Measuring economic policy uncertainty[J]. The Quarterly Journal of Economics, 2016, 131(4): 1593-1636.
- [54] 何青, 钱宗鑫, 刘伟. 中国系统性金融风险的度量——基于实体经济的视角[J]. 金融研究, 2018(4): 53-70.
- [55] SUN M, CHEN Y. Market volatility spillover, network diffusion and financial systemic risk management: financial modeling and empirical study [J]. Mathematics, 2023, 11(6): 1396-1396.
- [56] CHEN N, LIU X, YAO D D. An optimization view of financial systemic risk modeling: network effect and market liquidity effect[J]. Operations Research, 2016, 64(5): 1089-1108.
- [57] AMIHUD Y. Illiquidity and stock returns II: cross-section and time-series effects [J]. Review of Financial Studies, 2020, 34(4): 2101-2123.
- [58] 张宗新, 林弘毅, 李欣越. 经济政策不确定性如何影响金融市场间的流动性协同运动? ——基于中国金融周期的视角[J]. 统计研究, 2020, 37(2): 37-51.
- [59] 陈亚飞. 我国金融机构系统性风险度量研究[D]. 杭州: 浙江工业大学, 2019.
- [60] 纪森, 李宏瑾. 当前我国中小银行风险成因及政策建议 [J]. 金融理论与实践, 2019(12): 48-54.

Measuring Yield Risk in China's Commercial Banks Based on Expectile Regression Forest Model

YAN Fulei¹, YU Chenxi¹, ZHANG Gaoxun²

(1. School of Economics and Management, Southwest University of Science and Technology, Mianyang 621010, Sichuan, China;

2. School of Science, Southwest University of Science and Technology, Mianyang 621010, Sichuan, China)

Abstract: In the financial business, effective risk avoidance and mitigation are perennial themes. In the face of the international economic and financial environment has become more complex and severe, extreme events caused by the tail risk brought about by the harm is very strong, China's banking industry risk prevention and control work will face new challenges. Therefore, under the current globalization and complex and severe economic and financial environment, it is of great practical significance to improve the prediction ability of yield risks of commercial banks and take timely measures to prevent and resolve the risks. Selecting the monthly data of China's A-share listed commercial banks from January 2013 to December 2022, a nonparametric Expectile Regression Forest(ERF) risk prediction model based on the Bagging algorithm to measure the tail risk of China's commercial banks, and simultaneously incorporates the bank leverage ratio, asset size, economic policy uncertainty, financial market volatility and liquidity into the model at the same time were constructed, and then the mean absolute error and root mean square error of the training set and test set data under different models and risk levels respectively was calculated. Finally, the results were compared with the traditional expected quantile regression(ER) model and Expectile Regression Tree(ERT) model to determine the respective predictive performance. The results show that the ERF model has outstanding performance in measuring the tail risk of commercial banks, and the estimation and prediction ability of the ERF model is significantly better than that of the ERT and ER models under different levels of risk. Further analysis reveals that the smallest and the largest errors in the prediction of tail risk of the four major types of commercial banks are those of the national large-scale commercial banks and the local rural commercial banks, respectively, and the error values of the joint-stock commercial banks and the local urban commercial banks are comparable. The error values of joint-stock commercial banks and local urban commercial banks are comparable.

Keywords: Expectile regression forests; commercial banks; yield risk; Bagging algorithm