

中国信用债券违约回收率分析^{*}

李向真¹ 刘士达² 王浩³

摘要 本文使用2014年至2021年违约兑付数据研究我国债券违约回收率。债券违约后一年(截至2021年末)的回收率均值为8%(11%),呈非对称两极分布,即集中于0%与100%的两侧。从不同时间窗口看,违约债券的“黄金回收窗口”为一年。存量债券占资产比例是影响违约回收率的重要因素。发债企业是否为国企、是否上市;债券有无担保人、是否在银行间市场发行;宏观变量中的短期国债利率水平、长短期国债利差等显著影响违约回收率。在违约回收率预测方面,机器学习模型明显优于线性回归模型。其中,集成学习类模型的预测效果最佳。

关键词 违约回收率;信用风险;机器学习

0 引言

从2014年3月“11超日债”违约以来,我国信用债违约数量和规模大幅增加,2018年更是达到千亿级别。信用风险成为中国债券市场投资者和监管机构必须面对的问题。违约概率(Probability of Default, PD)和违约回收率(Recovery Rate, RR)是信用风险的两大核心因素,也是信用债及信用衍生品定价的基石。国内有大量的文献研究违约概率^①,然而欠缺对违约回收率的定量和预测研究^②。为了填补研究空白,本文重点研究如下三个问题:我国的债券违约回收率的统计特征是怎样的?哪些因素影响回收率?哪些模型可以更好地预测违约回收率?

我们手动收集了2014年至2021年我国信用债违约兑付数据,并按债券清算价值测算了违约回收率(即违约后历次回收的现金流之和除以违约发生时债券余额)。从均值来看,违约后一年的违约回收率均值为8.01%;截至2021年末,平均违约回收率为11.32%。相比较,穆迪信用评级公司给出的美国公司债违约回收率均值为42.58%。Asarnow and Edwards(1995)、Gupton et al. (2000)、Caselli et al. (2008)等测算的回收率均值也普遍在

^{*} 本研究受清华自主科研基金(项目号2023THZWJC20)的资助。

¹ 李向真(通信作者),清华大学经济管理学院博士研究生,E-mail:lixz22@mails.tsinghua.edu.cn。

² 刘士达,全国社会保障基金理事会(本文仅代表作者个人观点,不代表所在机构意见),E-mail:liushd.17@sem.tsinghua.edu.cn。

³ 王浩,清华大学经济管理学院副教授,E-mail:wanghao@sem.tsinghua.edu.cn。

① 见王浩和刘士达(2022)。

② 见林青和郝帅(2017)和刘逸凡等(2020)。

40%以上。这表明我国债券违约回收率相对较低。

从分布来看,我国债券违约回收率离散程度较高,呈“非对称两极分布”,即大多数违约债券要么从未兑付,要么兑付了绝大部分违约金额。在国外,Asarnow and Edwards (1995)、Caselli et al. (2008)等也发现了类似的特征,不同的是在国外市场,违约回收率为100%的债券占比更高。从回收时间窗口长度来看,回收率在一年后趋于稳定,说明“黄金回收窗口”为一年。在全部样本中,仅有2.89%的债券存在违约一年以后的兑付记录。

我们进一步研究影响违约回收率的因素。国外文献发现债项属性、发行企业特征和宏观经济三个层面的变量与违约回收率相关。我们使用OLS线性回归模型与机器学习模型的结果均表明,发行企业存量债券余额占总资产规模比例对违约回收率的解释力度最高,即需要偿还的债券规模越大,债务人越难以偿还全部债务,回收率也因此更低。在其余变量上,线性回归模型更看重债券特征(有无担保人、是否在银行间市场发行)和企业特征(是否为国企、是否为上市公司),而机器学习模型则表明宏观经济特征(短期国债利率水平、长短期国债利差)对于回收率的解释力度更大,产生这一分歧的原因还在于对回收率分布的假设以及算法机制^①。

我们基于上述影响回收率的因素探讨和评估主流的回收率预测模型。从样本外拟合程度的评估指标来看,机器学习模型要显著优于线性模型。违约回收率遵循“非对称两极分布”,而线性回归模型泛化能力有限,预测结果接近以0为中心的对称分布,背离了事实且没有形成对回收率的有效预测。相较而言,Gradient-Boosting等集成学习算法预测结果的分布更加契合回收率的实际情况,说明它们对回收率有较好的预测能力。在机器学习模型中,集成学习类模型的效果最好。

本文的贡献如下。第一,研究为我国市场信用风险定价提供了核心参考数据。主流信用风险定价模型,如结构化模型(Longstaff and Schwartz, 1995; Leland and Toft, 1996),和简化模型(Jarrow et al., 1997; Duffie and Singleton, 1999)均需要外生给定的回收率参数。本文总结了我国信用债券违约回收率统计特征,例如,我国债券违约后一年的平均违约回收率为8%,为中国信用风险定价实践提供关键参数。在此意义上,研究为完善我国信用评级市场提供基础信息。第二,国际三大评级机构标普、穆迪和惠誉均已开展回收率评级,我国在信用债违约常态化背景下,亟须补齐相应短板,增强评级对信用风险的识别作用(林青和郝帅, 2017)。我们在陈忠阳(2004)、沈沛龙和崔婕(2005)基础上运用线性回归模型与机器学习模型分析了宏观因素、发行企业、债券特征中影响回收率的重要因素,为完善国内评级体系、增强信用风险监管与防范、减小违约经济损失提供帮助。最后,从中国信用债市场发展来看,本文对中国市场回收率的量化分析与预测是开发信用衍生品的前提之一。信用衍生品是西方成熟金融市场的重要组成部分,在信用市场稳定发展中扮演关键角色(Stulz, 2010)。

^① 在分布假设上,OLS线性模型会隐含正态分布的假设,其对回收率的解释力度实则较低;而机器学习模型多为非线性模型,对回收率的解释力度要明显高于OLS。在算法机制上,Strobl et al. (2007)指出,排序重要性更倾向于筛选连续变量和分类较多的离散变量,对0/1变量存在“歧视”,这也使得机器学习模型不易把债券特征(有无担保人、是否在银行间市场发行)和企业特征(是否为国企、是否为上市公司)变量作为有解释力度的重要变量。

本文其余部分安排如下:第1部分回顾研究文献;第2部分总结违约回收率的统计特征;第3部分分析违约回收率的影响因素;第4部分对比分析违约回收率预测模型;第5部分总结全文。

1 文献综述

本节从四个方面对违约回收率相关文献进行回顾。我们首先展示回收率的度量方式,随后总结回收率的影响因素,然后对回收率预测文献进行回顾,最后对国内已有研究做总结。

1.1 度量方式

根据已有文献,对回收率的度量主要有清算法和市场法两种方式。

(1) 清算法是指根据实际偿付情况计算得到的、真实发生的回收率,其原理是将回收期间的现金流折现得到回收率。理论上,回收率等于回收现金流价值除以假如未违约情况下未来现金流价值。其优点是对债券、贷款等各种形式债务的市场流动性没有要求,因此能够帮助银行或其他债权人计算出该项债务最终实现的回收率。针对银行贷款,Asarnow and Edwards (1995)发现花旗银行1970—1993年间工商企业贷款平均回收率为65.21%,结构化贷款平均回收率为87.25%;Caselli et al. (2008)使用意大利银行清算的贷款回收数据作为样本,进而计算出平均回收率为46%。

使用清算法可以反映债务回收的实际过程。但是在实际操作中,清算法仍面临诸多问题,例如,如何确定现金流结构(现金流规模、回收时间的合理性)、如何设定回收期限、如何选取折现率等。这些细节处理上的差异将直接影响度量结果。

(2) 市场法是指利用市场有效理论,从债务(特别是债券)价格信息中获取市场预期的回收率。理论上,如果市场是有效的,那么违约时点附近的债务价格应该反映了市场对该债务回收率的预期,例如面值为100元的债券在违约后1天的交易价格信息为40元,表明市场认为债务在违约后的价值为40元,回收率即为40%。

若债权人能够在债务违约后通过市场交易实现一次性收回,则计算回收率时不必再考虑未来的债务实际偿还情况,省去了清算法折现估值的过程。穆迪公司(Carty and Lieberman,1996)使用1991年至1996年违约事件发生后美国企业债券价格的均值来计算市场回收率,其结果表明高级有担保贷款的平均回收率为57%,高级无担保贷款的平均回收率为46%。Carty et al. (1998)在穆迪的基础上,研究了200笔银行贷款的违约和回收数据。他们额外考虑了实际偿付、时间等因素,将违约后债务的市场价值作为计算回收率的依据,其结果表明高级有担保贷款的平均回收率为86.7%,高级无担保贷款的平均回收率为79.4%。Gupton et al. (2000)对穆迪公司(Carty and Lieberman,1996)所作研究进行了拓展,在研究181支违约银行贷款的回收率时,关注违约发生一个月后的债务工具二级市场价格,以确保市场有充足的时间处理违约信息并重新估算违约价值,他们发现高级有担保债券和高级无担保债券的回收率分别为59.1%和45.1%。Acharya et al. (2007)则使用了破产申请前违约债务工具的交易价格,以及在结算或清算(例如,收购、再

融资、不良交易等)中最早可用交易价格计算得到的平均回收率为51.1%。

使用市场法计算回收率的优点在于操作简单,但是其也存在局限性。对于没有市场需求的违约证券,一方面,交易价格可能不存在;另一方面,即使价格存在,该价格信息也不一定能够准确地反映均衡状态下的回收价值。

1.2 影响因素

从文献来看,影响回收率的因素从微观到宏观可分为债项属性、发行企业特征、行业类型以及宏观经济条件四个层面。

(1) 债项属性。债项属性主要指债券的优先级别与担保情况。Altman and Kishore(1996)测算了1978至1995年美国各类违约债券的回收率,发现其均值随着优先级及担保水平的下降而降低。Gupton et al.(2000)也发现了类似的现象,并进一步指出债项优先级和担保是影响回收率的重要因素。此后,Schuermann(2004)、Amiram(2011)等学者基于不同的数据集的研究结果佐证了上述结论。

(2) 发行企业特征。已有文献研究了企业债务规模和企业自身规模与回收率的关系,但研究结论存在分歧。关于债务规模,Han and Jang(2013)研究了韩国中小企业违约数据,指出企业债务规模与回收率呈负相关。然而,基于美国市场中穆迪、花旗违约数据的研究表明,债务规模对回收率的影响并不显著(Asarnow and Edwards, 1995; Carty et al., 1998)。关于企业规模,研究同样存在争议。韩国市场的数据支持回收率与企业规模负相关关系(Han and Jang, 2013);而Thorburn(2000)对瑞典违约数据的研究表明,企业规模与回收率不存在显著相关关系。

(3) 行业类型。Altman and Kishore(1996)发现公共事业、石油化工、橡胶塑料行业的违约回收率显著高于其他行业。Acharya et al.(2007)从行业周期角度进行了分析,他们发现处于低迷期的行业,其整体回收率明显更低。这是因为在行业整体不景气、流动性降低的情况下,企业更难通过变卖固定资产偿还债务。然而,Gupton et al.(2000)对不同行业的违约贷款回收率进行了T检验和Kruskal-Wallis检验,并未得出显著性的结论。

(4) 宏观经济。Altman and Kishore(1996)、Dalianes(1999)均发现回收率会随时间而波动。Caselli et al.(2008)的研究表明,违约率、失业率和家庭消费变化对个人消费贷款违约回收率的解释能力较强;就业率、GDP增长率对企业贷款违约回收率的解释能力较强。Nazemi and Fabozzi(2018)对179个宏观经济变量进行筛选,最终选出了存款机构超额准备金、不良贷款占比等对回收率有较好解释能力的宏观经济变量。

1.3 预测违约回收率

基于违约回收率影响因素,业界和学界也在探索回收率预测模型。Frye(2000)较早进行了尝试,构建了使用市场风险作为解释因子的单因子模型,预测违约主体的回收率,但其模型假设回收率服从正态分布,与实际情况存在较大偏差。此后的模型开始关注具体债项的回收率,引入多个宏观经济指标与债券特征作为解释变量。其中最具代表性的是穆迪的LOSSCALC模型(Gupton and Stein, 2002)。解释因子方面,LOSSCALC涵盖了债项属性、公司特征、行业特点和宏观经济四个层面;该模型假设回收率遵循Beta分布,

可以适应偏态分布情况。受 Gupton and Stein(2002)启发,后续学者继续尝试了更多的广义线性回归模型,用以解决违约回收率分布非正态的问题。例如:Dermine and De Carvalho(2006)使用 Fractional Response 回归预测葡萄牙银行贷款的回收率;Loterman et al. (2012)使用同时 OLS 回归、Beta 转换后的 OLS 回归、Box-Cox 转换后的 OLS 回归、Ridge 回归等多种传统回归模型预测商业银行贷款回收率,结果显示这些模型的预测效果差异不大。

随着机器学习技术的发展,人们开始尝试利用决策树、支持向量机、神经网络等主流机器学习算法预测违约回收率。Bastos(2010)使用葡萄牙商业银行 1995 到 2000 年 374 笔违约贷款数据构建了基于分类回归树的回收率预测模型。在测试集的结果显示,对于 12 个月和 24 个月的时间窗口,回归树预测的均方根误差明显低于历史均值法。Yao et al. (2015)使用穆迪数据库中的美国违约债券数据训练了 SVR 模型,并与 OLS 回归、Fractional Response 回归和 Beta 回归等进行了对比。无论样本内还是样本外,SVR 模型的 R -Squared、RMSE 和 MAE 等指标均优于上述传统回归模型。Qi and Zhao(2011)构建了一个三层神经网络模型,样本外测试结果显示,神经网络模型的 R -Squared 指标优于 OLS 回归、Fractional Response 回归等传统模型。

1.4 国内相关研究

我国关于回收率的研究多基于信贷领域。例如,陈忠阳(2004)从巴塞尔新资本协议的角度,系统地介绍了回收率与违约损失率的性质特点、重要性和影响因素等,并就量化方法进行了探索。沈沛龙和崔婕(2005)总结国外文献,认为影响违约回收率的可能因素包括债务资质、经济周期、行业差异、规模大小以及与违约概率的关系。何自力(2006)、陈光忠等(2010)及黄建忠和褚保金(2011)分别使用广东地区某商业银行抵押贷款处置数据、四川省大额违约贷款数据和江苏某银行历史债项数据研究了影响回收率的因素。代太山等(2008)依据东和数据咨询 LossMetrics 数据库中 1982—2006 年中国不良贷款数据,分析了不同担保类型的不良贷款回收率特征。杨军等(2009)根据中国银行业的实际情况,提出建立在清收基础上的历史平均违约损失率($1 - \text{回收率}$)较为实用的观点,以此建立了违约损失率决策树模型。

债券违约方面,林青和郝帅从信用评级角度介绍了国际评级机构的回收率评级方法;刘逸凡等(2020)归纳分析了不同情形(例如行业、债券类型、信用评级)和处置方式下的回收率情况。随着我国信用债市场迅速发展及对信用衍生产品的潜在需求日益增加,作为基础工作,对债券的违约回收率进行技术分析和预测的重要性凸显。关于债券违约回收率的实验方法和探讨可以被借鉴于信贷领域研究。本文研究侧重于违约回收率的统计特征分析和预测。

2 违约回收率特征

本节首先说明数据来源,随后对我国债券违约回收率的整体特征和时间序列特征做描述性统计。

2.1 数据来源

本文选取的样本区间为2014年3月(“11超日债”违约)至2021年12月,宏观经济数据以及债券属性特征来自万得数据库,违约债券的兑付数据由公司公告、法院判决书等公开渠道手动收集、整理而来。本文对原始数据进行了如下处理:(1)剔除全部技术性违约债券;(2)对于在银行间与交易所均进行交易的债券,剔除重复记录;(3)剔除违约时间不足一年的债券;(4)剔除了债券类型缺失的债券,剔除了交易商协会ABN、证监会主管ABS和集合企业债三类债券。需要强调的是,我们收集的违约兑付数据仅包括公开渠道可以查询的部分,由于私募债等债券的兑付信息披露不足,本文测算的回收率可以看作真实回收率的下界值。

经上述处理后,我们筛选出523只违约债券,发行规模共计4871.95亿元,其中104只债券存在违约后的偿付记录。

2.2 回收率的度量及统计特征

2.2.1 回收率的度量

1.1节提及回收率有市场法和清算法两种度量方式。由于国内违约债券缺乏市场流动性,违约后鲜有交易数据,不能够准确反映均衡状态下的回收价值^①。因此本文基于债券清算价值,测算了中国信用债违约回收率。回收率 R 的测算式如(1)所示,其中 P_0 为违约发生时的债券余额, $\sum C_t$ 为债券违约以来至时间点 t 之间历次兑付的现金流之和:

$$R = \frac{\sum C_t}{P_0} \quad (1)$$

我们计算了两类时间节点,一类为违约后一年,另一类为截至2021年末。

2.2.2 统计特征

表1给出了我国债券违约回收率的统计情况。整体来看,中国违约债券的回收率均值很低。截至2021年末,我国回收率的平均值为11.32%;截至各只债券违约后1年,我国回收率的平均值为8.01%。两者均低于穆迪给出的美国公司债违约回收率42.58%。从分布来看,回收率离散程度较高,不论是截至2021年末还是截至违约后一年,回收率的标准差在25%~30%。Acharya et al. (2007)测得美国公司债回收率标准差为36.58%。由于我国平均回收率低,回收率的差异性相对更大。

表1 回收率测算结果

统计截至时点	数量	平均值	标准差	最小值	P25	P50	P75	最大值
2021年末	523	11.32%	29.92%	0.00%	0.00%	0.00%	0.00%	100.00%
违约后一年	523	8.01%	25.77%	0.00%	0.00%	0.00%	0.00%	100.00%

^① 523支违约债券中有52只存在违约后的交易记录,占比仅为9.94%;另一方面,存在交易价格的债券中,26支债券交易记录小于2笔,占比50%。

图 1 给出了违约回收率的分布情况,整体呈“非对称两极分布”,即集中于 0 与 100% 的两侧。大多数违约债券要么从未有过兑付记录,要么兑付了绝大部分违约金额。Asarnow and Edwards(1995)、Caselli et al. (2008)等的研究也发现了类似的特征。不同点在于,国外回收率为 100% 的债券占比更高。




图 1 回收率分布情况

2.2.3 时间序列特征

我们采用了账龄分析的方法。图 2 报告了历年违约债券回收率均值在周、月、季度、年等不同时间窗口内变化的情况。




图 2 历年回收率随时间窗口变化情况

从时间趋势看,违约债券的回收率呈逐年下降趋势。一方面,2015 年及以前违约的债券的回收率最高,平均值接近 30%。在此期间,每年违约债券数量不超过 60 只。违约企业集中在钢铁、机械以及化工等在供给侧结构改革中承压的行业。2018 年开始,回收率出现了较大幅度下跌,该年回收率均值仅为 6.94%。另一方面,每年的违约债券数量增加到 100 至 200 只,零兑付的债券相应增加,信息技术、医疗保健以及日常消费等行业也出现大批违约事件,违约进入常态化。

从不同时间窗口看,违约债券的“黄金回收窗口”为一年。历年违约的债券的回收率

均在一年后趋于稳定。在全部样本中,仅有 2.89% 的债券存在违约一年以后的兑付记录。

3 影响因素

本节研究影响我国债券违约回收率的因素。我们首先说明选取的变量,随后使用线性回归和机器学习模型分析这些变量与回收率之间的关系。

3.1 变量特征

本文参考过往文献,结合数据可得性进行变量筛选,选取了债券特征、企业特征及宏观经济特征三个层面的变量来分析。表 2 给出了各类变量的描述性统计。

表 2 因子描述性统计

变量名称	数量	平均值	标准差	最小值	最大值
Panel A: 债券特征因子					
票面利率/%	523	6.94	1.30	3.00	11.00
期限/天	523	1252.40	607.18	90.00	3652.00
担保人(1 为有)	523	0.16	0.37	0.00	1.00
银行间市场(1 为是)	523	0.43	0.50	0.00	1.00
基金持有数占存量比/%	523	0.16	0.94	0.00	10.03
Panel B: 企业特征因子					
存量债券余额/总资产/%	523	15.72	17.54	0.02	122.66
国有企业(1 为是)	523	0.20	0.40	0.00	1.00
上市公司(1 为是)	523	0.23	0.42	0.00	1.00
Panel C: 宏观经济特征因子					
短期国债收益率/%	523	2.27	0.43	1.00	3.96
长短期国债利差/%	523	0.94	0.30	-0.06	1.60

债券特征变量考虑了债券发行、流过程中的特征。例如,票面利率与企业的信用水平和宏观经济状况相关;债券期限的背后是债券价值的不确定性。大部分违约债券没有担保人——仅 16% 的债券有担保;有超过四成的债券在银行间交易。Amihud et al. (2000)曾指出,机构投资者对债务的分析能力、对发债企业的监督能力都高于普通投资者。因此在银行间市场交易的债券,其回收情况可能优于在交易所市场流通的债券;关于基金持有情况。考虑到基金公司拥有强大的投研团队,其持仓情况可能反映债券的预期回收率。

企业特征变量考虑了发债企业的偿债压力与属性特征。首先是发行主体的存量债券余额在总资产中的占比,其反映企业整体的偿债压力,该变量均值约为 16%。其次是企业的性质,包括是否为国有企业以及是否为上市公司。20% 的违约发债主体为国企,23% 的违约发债主体是上市公司,国企隐性担保和上市公司的融资能力都是可能影响企业偿债的重要因素。

宏观经济特征包括违约前的经济基本面情况。本文主要使用国债收益率,包括短期国债收益率(3 个月期)以及长短期国债利差(10 年期国债与 3 个月期国债的利差)。利率期

限结构反映了货币政策的走向以及市场对未来经济的预期(Gilchrist and Zakrajšek, 2012)。

3.2 结果分析

我们采用线性回归和机器学习的方法来研究上述变量与回收率之间的关系。我们首先参考 Jankowitsch et al. (2014) 采用传统的 OLS 线性回归模型来直观地考察上述变量与违约回收率之间的关系。同时我们也采用了 6 种机器学习模型(支持向量、K 近邻、随机森林、Gradient-Boosting 回归树、Ada-Boosting 回归树和 Bagging 回归树)来进一步分析影响回收率的核心变量。

使用两种方法的原因在于, OLS 线性回归可以直观给出各个变量对回收率的影响大小与方向, 但回收率非正态分布的特征会影响线性回归的解释力度; 机器学习模型非线性特征更符合回收率实际情况, 解释能力更强, 但这类“黑箱”模型只能得到各个变量相对重要性的排序, 不如线性模型简明直观。

3.2.1 OLS 模型分析

表 3 给出了前述变量与回收率的关系。从统计显著性而言, 有 5 个变量在统计上显著。有担保人的债券在回收率上显著高于没有担保人的债券, 这符合经济学直觉——担保作为增信的手段之一起到提高对债权人的保护的作用。在银行间市场发行的债券回收率要显著更高, 这是由于能在银行间市场发行的债券资质相较交易所市场更高, 因此偿付能力也相应更强。存量债券余额占总资产规模比例越大, 违约回收率越低, 经济学直觉上, 需要偿还的债券规模越大, 债务人越难以偿还全部债务, 回收率也因而更低。发债公司的国企和上市公司性质对回收率也有影响。尽管这种影响更多体现在违约后一年的回收率上, 但从系数来看, 国有企业和上市公司的回收率显著更高, 即隐性担保和融资能力为偿债起到了一定的保障作用。林晚发等(2020)的研究也表明, 国有企业由于预算软约束的存在, 信用评级更高, 且控股股东可通过关联交易、财政补贴等方式保护被控股公司。

表 3 OLS 模型下各变量与回收率关系

	(1) 回收率(截至 2021 年末)	(2) 回收率(截至违约后一年)
票面利率	-0.02 (-1.59)	-0.01 (-1.12)
期限	-0.00 (-0.48)	-0.00 (-1.40)
担保人	0.08* (1.80)	0.07* (1.76)
银行间市场	0.08*** (2.84)	0.06** (2.55)
基金持有数占存量比	0.02 (0.90)	0.01 (0.68)
存量债券余额/总资产	-0.17*** (-2.66)	-0.16*** (-2.61)

续表		
	(1)	(2)
	回收率(截至 2021 年末)	回收率(截至违约后一年)
国有企业	0.04 (1.10)	0.06* (1.67)
上市公司	0.04 (1.18)	0.06** (2.00)
短期国债收益率	0.06 (1.10)	0.03 (0.58)
长短期国债利差	-0.05 (-0.71)	0.01 (0.08)
Obs	523	523
Adj R-squared	0.044	0.039

注：***、** 和 * 分别表示在 1%、5% 和 10% 水平上显著。

3.2.2 机器学习模型分析

我们在这一部分使用全部数据做样本内分析。为了直观比较不同特征变量在解释回收率方面的作用,本文使用排序重要性(Permutation Importance)进行分析(Breiman, 2001;陆瑶等,2020)。机器学习类算法本身为“黑箱”,无法直接观测特征变量在模型中所起的作用。排序重要性通过比较各个变量被“破坏”前后对模型性能的影响程度,分析特征变量的相对重要性,提升了模型的可解释性。

单个特征因子的排序重要性取决于将该特征随机重排、破坏原有的对应关系后,模型性能评价指标的下降程度。假设模型 m 的性能评分为 s ,对于模型中的特征因子 i ,其排序重要性 p_i 的计算方式为

$$p_i = s - \frac{1}{K} \sum_{n=1}^K s_{n,i}$$

(2)

其中, K 表示随机重排 i 的次数。某特征因子的排序重要性越大,表明其对解释回收率的贡献越大。

表 4 显示,连续变量中,存量债券余额占总资产规模比例对解释违约回收率有重要贡献,这与 OLS 的结果相一致。前面 OLS 结果表明,企业需要偿还的债券规模越大,违约回收率更低。债券票面利率和债券期限也有助于预测违约回收率,这一结果也说明了我国债券市场具有信息发现能力和有效性。此外,违约回收率受到宏观市场的影响,具体体现在国债收益率和利率期限结构的陡峭程度上。最后,上市公司、国有企业等离散变量排序重要性较低,这是由算法机制决定的,并不意味着其对解释回收率的贡献小。Strobl et al. (2007)指出,排序重要性更倾向于筛选连续变量和分类较多的离散变量,对 0/1 变量存在“歧视”。因此,我们主要关注其对连续变量的分析结果。

表 4 机器学习模型下各变量与回收率关系

	SVR	KNN	RF	GDB	ADB	BAG	均值
存量债券余额/总资产	0.121	0.630	0.431	0.470	0.290	0.563	0.417
票面利率	0.251	0.801	0.266	0.320	0.143	0.347	0.354

	续表						
	SVR	KNN	RF	GDB	ADB	BAG	均值
期限	0.264	0.710	0.271	0.275	0.117	0.319	0.326
短期国债收益率	0.209	0.735	0.275	0.280	0.091	0.351	0.323
长短期国债利差	0.228	0.752	0.245	0.228	0.060	0.288	0.300
银行间市场	0.076	0.443	0.212	0.056	0.039	0.059	0.147
上市公司	0.087	0.327	0.114	0.032	0.015	0.032	0.101
国有企业	0.039	0.270	0.082	0.020	0.003	0.022	0.073
担保人	0.042	0.234	0.055	0.011	0.002	0.010	0.059
基金持有数占存量比	0.067	0.096	0.024	0.028	0.013	0.030	0.043

注:SVR为支持向量模型,KNN为K近邻模型,RF为随机森林模型,GDB为Gradient-Boosting回归树模型,ADB为Ada-Boosting回归树模型,BAG为Bagging回归树模型。

4 回收率预测

回收率的预测属于信用风险领域的关键问题。从资产定价来看,回收率是信用风险定价模型核心参数之一。主流的结构化模型(structural-form model)(Longstaff and Schwartz,1995; Leland and Toft, 1996)与简化模型(reduced-form model)(Jarrow et al., 1997; Duffie and Singleton,1999)均需要外生给定的回收率参数才能完成定价;从信用评级来看,国际三大评级机构标普、穆迪和惠誉均已开展建立在回收率预测基础上的回收率评级,我国在信用债违约趋于常态化背景下,亟须补齐相应短板;从中国信用债市场发展来看,可信的回收率预测也将为我国开发信用衍生产品,例如信用违约互换(Credit Default Swap)等奠定基础。因此,简单将回收率视为常数,或直接使用历史均值已无法满足上述需求,以机器学习为代表的非参数模型可以灵活拟合不同的函数形式,挖掘潜在关系,适用于解决回收率的预测问题。

本节利用前述十个影响因素和机器学习模型尝试对我国债券回收率进行预测。我们首先说明预测模型的评价方式,随后探讨不同机器学习模型的预测表现。

4.1 评价方式

鉴于违约回收率样本数据的分布极不均匀,本文均遵循分层抽样的原则,将样本数据按照训练集与测试集7:3的比例进行划分,保证每一对训练集与测试集数据中回收率的分布都与样本整体保持一致,进而比较不同模型在样本外的预测性能。本文使用网格搜索调节超参数,并使用交叉验证法进行评估。

回收率预测的对象为连续变量,相对应的评价指标主要有均方误差(mean squared error,MSE)、平均绝对误差(mean absolute error,MAE)以及可决系数(R-Squared)三类。假设测试集中,回收率的真实值为 r ,模型给出的预测值为 r' ,则三项指标定义如下:

$$MSE=\frac{1}{n}\sum_{i=1}^n\left(r'_i-r_i\right)^2$$

(3)

MSE 是最常见的评估指标,给出了误差平方的平均值,显然,MSE 越小,模型效果越好。

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |r'_i - r_i| \quad (4)$$

MAE 与 MSE 很像,给出了指标误差绝对值的平均数,同样,MAE 越小,模型效果越好。

$$R\text{-Squared} = 1 - \frac{\sum_{i=1}^n (r'_i - \bar{r})^2}{\sum_{i=1}^n (r_i - \bar{r})^2} \quad (5)$$

R-Squared 最大值为 1,其值越趋于 1,模型效果越好。

总体来看,MSE 对较大的异常值更为敏感,MAE 对较小的异常值更为敏感,R-Squared 则可衡量模型整体的解释力度,三者没有绝对优劣之分。

4.2 预测表现

表 5 给出了线性回归和机器学习模型在 MSE、MAE 和 R-Squared 三项性能指标的平均值。

表 5 模型样本外预测性能平均值

模型	MSE	MAE	R-Squared
OLS	0.0665	0.1452	0.0109
SVR(支持向量)	0.0625	0.1407	0.0714
KNN(K 近邻)	0.0626	0.1127	0.0688
RF(随机森林)	0.0593	0.1142	0.1178
Gradient-Boosting	0.0575	0.1206	0.1450
Ada-Boosting	0.0609	0.1292	0.0948
Bagging	0.0592	0.1145	0.1202

预测结果表明：

(1) 机器学习模型与线性模型比较而言,前者的性能普遍优于后者。在 6 种机器学习模型中,MSE、MAE 以及 R-Squared 三项评估指标均显著优于线性模型。从 R-Squared 角度看,这种差距尤为明显。OLS 回归的 R-Squared 仅有 0.01,而机器学习模型的 R-Squared 大多在 0.06 至 0.14。

(2) 在机器学习模型中,集成学习类模型预测效果最佳。其中,Gradient-Boosting 表现出色,R-Squared 达到 0.1450,大幅领先其余模型;MSE 为 0.0575,也是所有模型中的最佳。其余的随机森林、Ada-Boosting 以及 Bagging 等集成学习模型也同样表现良好。机器学习模型中,SVR 的效果最差,其 MAE 和 R-Squared 均处于垫底位置,且 MSE 也偏大。

预测结果的分布情况同样揭示了模型之间的差异。如图 3 所示,测试集的回收率遵循“非对称两极分布”。而 OLS 回归的预测结果接近以 0 为中心的对称分布,大量预测结果为负数,背离了事实,并没有形成对回收率的有效预测。相较而言,Gradient-Boosting 等集成学习算法预测结果的分布更加契合回收率的实际情况,说明它们对回收率有较好

的解释和预测能力。而机器学习模型中,SVR预测结果的分布明显偏离实际情况,其各项性能指标也是机器学习模型中最差的。中国市场回收率的分布特征要求预测模型具有强泛化能力,传统线性模型不能承担这一任务,而集成学习类模型通过集成“基学习器”使模型整体性能得以提升(周志华,2016),在回收率预测中起到了关键作用。




图3 模型回收率预测分布

5 结论

违约回收率是信用风险的决定因素之一,也是信用债券及信用衍生品定价的基础。

本文第一次使用公开数据对我国信用债违约回收率进行测算,给出了特征描述性统计。在我国,债券违约后一年的回收率均值为8%;截至2021年末的平均回收率为11%,大幅低于国外债券市场的回收率(40%以上)。违约回收率的分布特征呈“非对称两极分布,”即集中于0%与100%的两侧,这与国际市场相似。从不同时间窗口看,违约债券的“黄金回收窗口”为一年。从时间趋势看,违约债券的回收率呈逐年下降趋势。2015年及以前违约的债券的回收率最高,平均值接近30%。2018年开始,回收率出现了较大幅度下跌,该年回收率均值仅为6.94%。随着违约债券数量增加,回收率的标准差逐渐减小。

我们探讨了影响违约回收率的债券、企业及宏观经济特征。OLS与机器学习分析的结果均表明,存量债券余额占总资产规模比例与违约回收率负相关。线性模型更看重债券和发债企业特征变量(有无担保人、是否在银行间市场发行、是否为国企、是否上市)而机器学习模型更看重宏观变量(短期国债利率水平、长短期国债利差)。在违约回收率预测方面,泛化能力更好的机器学习模型明显优于线性回归模型;在机器学习模型中,集成学习类模型的预测效果最好,能更好地适应回收率的分布特征。

参考文献

- 陈光忠,唐小我,倪得兵. 2010. 银行违约损失率特征研究[J]. 中国管理科学, 18(2): 19-24.
- Chen G Z, Tang X W, Ni D B. 2010. The study on bank loss given default[J]. *Chinese Journal of Management Science*, 18(2): 19-24. (in Chinese)
- 陈忠阳. 2004. 违约损失率(LGD)研究[J]. 国际金融研究, (5): 49-57.
- Chen Z Y. 2004. Research on LGD[J]. *Studies of International Finance*, (5): 49-57. (in Chinese)
- 代太山,陈敏,杨晓光. 2008. 不同担保类型之下违约损失率的结构特征: 针对中国的实证[J]. 南方经济, (8): 28-39.
- Dai T S, Chen M, Yang X G. 2008. Structural characteristics of loss given default under credit guarantees: Empirical evidence for China[J]. *South China Journal of Economics*, (8): 28-39. (in Chinese)
- 何自力. 2006. 抵押贷款违约损失率研究[J]. 南方金融, (3): 30-31, 29.
- He Z L. 2006. Research on loss given default rate of mortgage loan[J]. *South China Finance*, (3): 30-31, 29. (in Chinese)
- 黄建忠,褚保金. 2011. 商业银行违约损失率的影响因素——基于江苏省某银行历史债项数据的分析[J]. 现代经济探讨, (8): 51-55.
- Huang J Z, Chu B J. 2011. The influencing factors of loss given default rate of commercial banks—Based on the historical debt data of a bank in Jiangsu Province[J]. *Modern Economic Research*, (8): 51-55. (in Chinese)
- 林青,郝帅. 2017. 国际评级机构回收率评级方法研究[J]. 债券, (12): 56-61.
- Lin Q, Hao S. 2017. Research on the recovery rate rating method of international rating agencies[J]. *China Bond*, (12): 56-61. (in Chinese)
- 林晚发,王雅炯,幸丽霞. 2020. 企业定性信息与债券信用评级: 基于股权性质的分析[J]. 中国软科学, (4): 123-131.
- Lin W F, Wang Y J, Xing L X. 2020. Qualitative information of enterprises and credit rating of bonds: Evidence from the nature of stock right[J]. *China Soft Science*, (4): 123-131. (in Chinese)
- 刘逸凡,王志雄,孙海容. 2020. 中国违约债券的回收率问题探究[J]. 债券, (3): 28-33.
- Liu Y F, Wang Z X, Sun H R. 2020. Research on recovery rate of bond default in China[J]. *China Bond*, (3): 28-33. (in Chinese)

- 陆瑶, 张叶青, 黎波, 等. 2020. 高管个人特征与公司业绩——基于机器学习的经验证据[J]. 管理科学学报, 23(2): 119-139.
- Lu Y, Zhang Y Q, Li B, et al. 2020. Managerial individual characteristics and corporate performance: Evidence from a machine learning approach[J]. *Journal of Management Sciences in China*, 23(2): 119-139. (in Chinese)
- 沈沛龙, 崔婕. 2005. 内部评级法中违约损失率的度量方法研究[J]. 金融研究, (12): 86-95.
- Shen P L, Cui J. 2005. The measurement of LGD in IRB approach[J]. *Journal of Financial Research*, (12): 86-95. (in Chinese)
- 王浩, 刘士达. 2022. 信用评级的中国实践——历史、现在与未来[M]. 北京: 清华大学出版社.
- Wang H, Liu S D. 2022. Credit rating and its practice in China-Past, present, and future[M]. Beijing: Tsinghua University Press. (in Chinese)
- 杨军, 程建, 潘俊武. 2009. 违约损失率模型开发的理论分析和实证研究[J]. 国际金融研究, (6): 71-78.
- Yang J, Cheng J, Pan J W. 2009. A theoretical and empirical study on LGD models[J]. *Studies of International Finance*, (6): 71-78. (in Chinese)
- 周志华. 2016. 机器学习[M]. 北京: 清华大学出版社.
- Zhou Z H. 2016. Machine learning[M]. Beijing: Tsinghua University Press. (in Chinese)
- Acharya V V, Bharath S T, Srinivasan A. 2007. Does industry-wide distress affect defaulted firms? Evidence from creditor recoveries[J]. *Journal of Financial Economics*, 85(3): 787-821.
- Altman E I, Kishore V M. 1996. Almost everything you wanted to know about recoveries on defaulted bonds[J]. *Financial Analysts Journal*, 52(6): 57-64.
- Amihud, Yakov, Kenneth Garbade, Marcel Kahan, 2000. An institutional innovation to reduce agency costs of public corporate bonds[J]. *Journal of Applied Corporate Finance*, (1): 114-121.
- Amiram D. 2011. Debt contracts and loss given default[D]. Chapel Hill: The University of North Carolina at Chapel Hill.
- Asarnow E, Edwards D. 1995. Measuring loss on defaulted bank loans: A 24-year study[J]. *Journal of Commercial Lending*, 77(7): 11-23.
- Bastos J A. 2010. Forecasting bank loans loss-given-default[J]. *Journal of Banking & Finance*, 34(10): 2510-2517.
- Breiman L. 2001. Random forests[J]. *Machine Learning*, 45(1): 5-32.
- Carty L V, Lieberman D. 1996. Defaulted bank loan recoveries[M]. New York: Moody's Investors Service Inc. .
- Carty L V, Hamilton D T, Keenan S C, et al. 1998. Bankrupt bank loan recoveries[M]. New York: Moody's Investors Service, Inc. .
- Caselli S, Gatti S, Querci F. 2008. The sensitivity of the loss given default rate to systematic risk: New empirical evidence on bank loans[J]. *Journal of Financial Services Research*, 34(1): 1-34.
- Dalians P C. 1999. Credit risk pricing: Summary and current methodology[J]. *Quantitative Models in Finance*.
- Dermine J, De Carvalho C N. 2006. Bank loan losses-given-default: A case study[J]. *Journal of Banking & Finance*, 30(4): 1219-1243.
- Duffie D, Singleton K J. 1999. Modeling term structures of defaultable bonds[J]. *The Review of Financial Studies*, 12(4): 687-720.
- Frye J. 2000. Depressing recoveries[J]. *Risk London Risk Magazine Limited*, 13(1): 108-111.
- Gilchrist S, Zakrajšek E. 2012. Credit spreads and business cycle fluctuations[J]. *American Economic Review*, 102(4): 1692-1720.
- Gupton G M, Gates D, Carty L V. 2000. Bank loan loss given default [M]. New York: Moody's Investors Service Inc. .
- Gupton G M, Stein R M. 2002. LossCalcTM: Model for predicting loss given default (LGD)[M]. New York: Moody's KMV Company.

- Han C, Jang Y. 2013. Effects of debt collection practices on loss given default[J]. *Journal of Banking & Finance*, 37(1): 21-31.
- Jankowitsch R, Nagler F, Subrahmanyam M G. 2014. The determinants of recovery rates in the us corporate bond market[J]. *Journal of Financial Economics*, 114(1): 155-177.
- Jarrow R A, Lando D, Turnbull S M. 1997. A Markov model for the term structure of credit risk spreads[J]. *The Review of Financial Studies*, 10(2): 481-523.
- Leland H E, Toft K B. 1996. Optimal capital structure, endogenous bankruptcy, and the term structure of credit spreads[J]. *The Journal of Finance*, 51(3): 987-1019.
- Longstaff F A, Schwartz E S. 1995. A simple approach to valuing risky fixed and floating rate debt[J]. *The Journal of Finance*, 50(3): 789-819.
- Loterman G, Brown I, Martens D, et al. 2012. Benchmarking regression algorithms for loss given default modeling [J]. *International Journal of Forecasting*, 28(1): 161-170.
- Nazemi A, Fabozzi F J. 2018. Macroeconomic variable selection for creditor recovery rates[J]. *Journal of Banking & Finance*, 89: 14-25.
- Qi M, Zhao X L. 2011. Comparison of modeling methods for loss given default[J]. *Journal of Banking & Finance*, 35(11): 2842-2855.
- Schuermann T. 2004. What do we know about loss given default? [R]. Working Paper.
- Strobl C, Boulesteix A L, Zeileis A, et al. 2007. Bias in random forest variable importance measures: Illustrations, sources and a solution[J]. *BMC Bioinformatics*, 8: 25.
- Stulz R M. 2010. Credit default swaps and the credit crisis[J]. *Journal of Economic Perspectives*, 24(1): 73-92.
- Thorburn K S. 2000. Bankruptcy auctions: Costs, debt recovery, and firm survival[J]. *Journal of Financial Economics*, 58(3): 337-368.
- Yao X, Crook J, Andreeva G. 2015. Support vector regression for loss given default modelling[J]. *European Journal of Operational Research*, 240(2): 528-538.

Analysis of Default Recovery Rate for Chinese Credit Bonds

Xiangzhen Li¹ Shida Liu² Hao Wang¹

- (1. School of Economics and Management, Tsinghua University;
2. National Council for Social Security Fund)

Abstract This article uses default data from 2014 to 2021 to study the recovery rate of credit bonds in China. The average recovery rate one year after bond default (as of the end of 2021) is 8% (11%), with an asymmetric bipolar distribution, concentrated on both sides of 0% and 100%. With different horizon, the gold recovery horizon for defaulting bonds is one year. The proportion of Existing bonds in assets is an important factor affecting the recovery rate. Besides, with or without guarantor, issued in the inter-bank market or not, state owned enterprise or not, publicly listed or not, short-term treasury rate and spread over long and short treasury rate significantly affect the default recovery rate. In terms of recovery rate prediction, machine learning models are significantly superior to linear regression models. Among them, the prediction of ensemble learning model is the best.

JEL Classification G21, G24, G28