

基于KMV模型的我国上市公司信用风险对比研究

刘烱秋

贵州大学经济学院, 贵州 贵阳

收稿日期: 2024年5月26日; 录用日期: 2024年6月14日; 发布日期: 2024年8月21日

摘要

近两年中国上市公司由于受到新的冠状病毒疫情的冲击, 经济增速放缓, 面临种种危机, 信用风险受到很大考验, 而规避违约风险对公司未来的发展不仅有益处, 而且在制度稳定性方面也将起到明显的作用。因此, 我们选择了KMV模型与GARCH模式和SV模式相结合, 对上市公司的股票收益波动率进行重新拟合和估算, 以此来衡量上市公司的资信管理, 采用调整后的GARCH-KMV模型和SV-KMV模型, 对上市公司中的9家ST企业与9家非ST企业的信用风险进行了对比研究。结果显示, 传统的KMV可以更好地衡量上市公司的信用风险, 在结合GARCH模型和SV模型后也可以衡量上市公司的信用风险, 但SV模型对于信用风险的解释效果要好于GARCH模型。

关键词

信用风险, KMV模型, SV模型

Comparative Study on Credit Risk of Listed Companies in China Based on KMV Model

Handi Liu

School of Economics, Guizhou University, Guiyang Guizhou

Received: May 26th, 2024; accepted: Jun. 14th, 2024; published: Aug. 21st, 2024

Abstract

Impacted by the COVID-19 pandemic, the growth rate of China's economy has slowed down, and listed companies in China are facing various crises. Credit risk is under significant testing, and avoiding default risk is not only beneficial for the future development of companies but also cru-

cial for the stability of the system. Therefore, this study employs the KMV model to measure the credit quality of listed companies and combines the GARCH and SV models to re-estimate the volatility of equity value for these companies. The revised GARCH-KMV model and SV-KMV model are then applied to compare and analyze the credit risk of 9 ST companies and 9 non-ST companies in the listed market. The results indicate that the traditional KMV model can effectively measure the credit risk of listed companies, and incorporating the GARCH and SV models improves its credit risk measurement. Furthermore, the SV-KMV model demonstrates a better explanatory effect on credit risk compared to the GARCH-KMV model.

Keywords

Credit Risk, KMV Model, SV Model

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

上市公司规避违约风险既有利于自身的可持续发展,又能有效规避系统性金融风险,无论是2008年的金融危机,还是新冠疫情,其信用风险的衡量始终是国内外十分关注的话题。过去几年有一些研究是对资产市值和资产市值波动幅度进行修正,其依据是对于KMV模型精确度的提高;也有研究对违约点来进行修正。但是有关研究表明由于股票收益波动率对于违约距离的贡献最大,因此本文决定根据GARCH模型和SV模型对股票收益波动率进行重新拟合估计,并将其运用于传统的KMV模型来结合比较分析。

2. 文献综述

目前,国内外对于信用风险的研究无论是理论方面还是实证分析都处于比较成熟的状态。早期的信用评估方法一般是采取定性的方式,例如,专家评估法、Altman于1968年建立的Z值积分模型[1],后续Altman又在1977年发展了将变量增至7个的ZETA模型等[2]。这些方法根据专家评级和历史财务指标来度量,最大的缺点在于过于依赖专家的主观判断和企业的财务指标,如果企业会计信息的统计存在错误,这一系列早期的度量方法就会出现较大误差。在20世纪90年代,科技的进步使得国内外的研究开始面向神经网络和人工智能等方向对历史数据建模来进行预测,这些方法相比早期的主观定性,对于信用风险的度量更加准确,但对于样本有着较多的选取条件,不适合广泛应用[3]-[5]。现代的风险计量模型加入了更多的影响因素,对上市公司的信用质量有了更全面的评估,目前被广泛应用的有Credit Metrics、Credit Risk+、KMV模型等。

由于现代的Credit Metrics模型等都比较依赖于信用评级机构的评级,在短期内并不能很好的解释信用风险,这一点不太符合也难以适用于中国实际;另外对于Credit Risk+模型而言,其参数又难以估计,且对于债务之间的要求独立;KMV模型则是从市场视角出发,对上市公司的信用风险计量进行了一定的计量,运用期权理论对公司资产进行了价值估计。近年来,国内外的研究也着力于改进KMV模型的精确度。如蒋正权、张能福(2008)运用GARCH(1,1)估计公司股权价值波,发现较传统KMV模型正态分布假设,较金融市场收益分布呈现尖峰肥尾特征更为符合[6];运用敏感性分析法的周子元、杨永生发现,各参数中对违约距离敏感度贡献较大的是股票收益波动率[7];王莉(2017)运用修正违约距离的KMV模型提高了上市公司财务危机预警解释精度[8];杨柳勇、王礼月(2018)引入资产价格跳跃因子结合Merton期

权定价模型构建了改进的 LJKMV 模型来测算违约距离计量信用风险[9]；段翀(2020)以 KMV 模型作为基础，运用 PFM 模型并采用倾向匹配得分法以测算中小企业信用风险[10]；孙亮、吕丹妮(2021)引入 GARCH、EGARCH、TARCH 三种模型来计算股权价值的波动率以弥补 KMV 模型无法处理收益率序列非正态分布的不足之处[11]。在信用风险测算精度不断优化的进程中，也有学者以 KMV 模型测算出的违约距离来度量企业违约风险，并将其作为变量引入实证模型以丰富多方领域的研究。具体来说，郭立仑、周升起(2022)以 KMV 模型测算的违约距离衡量信用风险并将其作为被解释变量，运用随机森林模型以探究商业银行信用风险的影响因素[12]；蔡真、林菁等(2023)将 KMV 模型估算出的违约距离引入面板模型中分析房地产调控政策对房地产企业违约风险的影响[13]。除了对于企业层面信用风险的研究，还有学者将 KMV 模型用于监控各级政府债务风险：凌华、周会洋等(2021)运用 KMV 模型对 Z 省 2021、2022 年地方政府专项债券的违约风险进行测算[14]；张慧、王宁等(2021)通过构建分形的 KMV 模型对 31 个省份地方政府债券的安全发行规模进行测算，发现虽然政府债券信用风险较小，但是其违约概率仍然会随着地方政府的发债规模占财政收入比例的扩大而增大[15]；李绍荣、刘星洋(2023)引入融资缺口、支付意愿、土地出让三个参数完善 KMV 模型，对各省城投债违约风险进行压力测试[16]。这些来自国内的一系列研究显示，无论是对于企业还是政府的信用风险度量，关键是在于准确估计股票收益波动率或是政府性基金收入波动率，以此来提高 KMV 模型的准确度，从而对上市公司、地方政府债券信用风险进行可靠度量。

参考余素红、张世英的研究结果：通过研究 SV 模型和 GARCH 模型对上证综指的拟合估计，最后得到了 SV 模型的拟合效应高于 GARCH 模型的结果，因此本文决定具体分别应用 GARCH 模型和 SV 模型对上市公司的波动率进行重新估算，再将其组合运用到 KMV 模型中[17] [18]。比较二者对于信用风险衡量的效果，最终结果显示 SV 模型比 GARCH 模型的拟合效果更好，更能对上市公司的信用风险质量做出准确解释。

3. 模型介绍

3.1. KMV 模型

1. 模型的构建

违约点 DP 为公司资产低于某一水平时，发生违约的点。公司债权人与债务人之间的差距被称为违约距离 DD 。预期违约概率 EDF 可以根据违约距离与违约概率之间的映射关系求得。预期违约概率 EDF 是指公司在获得借款后，发生违约行为导致借款无法偿还的可能性。KMV 模型认为，当公司清偿债务的资产余额小于负债的账面余额时，公司就会违约，由于难以知晓公司在此之前是否会做出违约行为，因此只能预测上市公司产生违约行为风险的高低。

KMV 模型的计算具体分为以下三个步骤：

(1) 计算公司资产市场价值及其波动率。其公式如下：

$$\frac{dV_A}{V_A} = \mu dt + \sigma_A dW_t \quad (1)$$

其中 V_A 表示公司资产的市场价值； μ ， σ_A 分别表示资产价值的均值和方差； DP 表示公司负债，从而得到公司总市值与资产价值的关系：

$$V_E = V_A N(d_1) - e^{-rT} XN(d_2) \quad (2)$$

其中， $d_1 = \frac{\ln\left(\frac{V_A}{DP}\right) + \left(r + \frac{\sigma_A^2}{2}\right)T}{\sigma_A \sqrt{T}}$ ， $d_2 = d_1 - \sigma_A \sqrt{T}$ ， V_E 为公司股权价值， $N(\cdot)$ 表示服从正态分布的累

积概率函数, r 为无风险利率, T 为偿还期限。

综上可得到股权波动率:

$$\sigma_E = \frac{V_A}{V_E} \frac{\partial V_E}{\partial V_A} \sigma_A \quad (3)$$

其中, σ_E 表示股权价值波动率, $\frac{\partial V_E}{\partial V_A} N(d_1)$ 。

通过(1)、(2)和(3)可以求出资产的市场价值及其波动率。

(2) 计算违约距离 DD 。其公式如下:

$$DD = \frac{V_A - DP}{V_A \sigma_A} \quad (4)$$

(3) 计算违约概率 EDF 。其公式如下:

$$EDF = P(E(V_A) \leq DP) = N\left(\frac{DP - E(V_A)}{E(V_A) \cdot \sigma_A}\right) = N(-DD) \quad (5)$$

理论的预期违约概率与实际存在较大差异, 统计出在违约距离相同的公司中发生违约行为的公司数量, 可求得经验违约率:

$$\text{经验 } EDF = \frac{\text{违约距离为 } n \text{ 的企业中违约的企业数量}}{\text{违约距离为 } n \text{ 的所有企业数量}} \quad (6)$$

违约距离与违约概率之间的映射关系难以准确把握, 对于中国实际而言可能存在较大误差。所以本文不采用违约概率对中国上市公司的信用风险进行度量, 选择直接运用违约距离来进行解释。

2. 参数设定

(1) 股权价值 V_E 。本文选用的是 2021、2022 两年的股票市场数据, 分为流通股股权和非流通股股权, 这两部分的计算公式如下:

$$\text{非流通股价值} = \text{非流通股数} \times \text{每股价值} \quad (7)$$

$$\text{流通股价值} = \text{流通股数} \times \text{平均收盘价} \quad (8)$$

$$\text{股权价值 } V_E = \text{流通股价值} + \text{非流通股价值} \quad (9)$$

(2) 无风险利率 r 。本文采用央行公布的 1 年期定期存款利率平均值来表示, 其中 $r = 0.015$ 。

(3) 违约点 DP 。其公式如下:

$$DP = SD + 0.5 * LD \quad (10)$$

其中, SD 流动负债, LD 长期负债。

(4) 股权价值波动率 σ_E 。股票的日对数收益率公式为:

$$u_t = \ln \frac{P_{t+1}}{P_t} \quad (11)$$

其中, P_t 表示 t 时刻收盘价, P_{t+1} 表示第 $t+1$ 时刻收盘价, 股票的日收益率标准差 σ_* 为:

$$\sigma_* = \sqrt{\frac{1}{n-1} \sum_{t=1}^n (P_t - \bar{P})^2} \quad (12)$$

其中, $\bar{P} = \frac{1}{n} \sum_{t=1}^n P_t$, $\bar{P}$ 表示日平均收益率。

由于每年的交易日为 250 天左右, 因此 σ_E 与 σ_* 的关系为:

$$\sigma_E = \frac{\sigma_*}{\sqrt{t}} = \frac{\sigma_*}{\sqrt{\frac{1}{250}}} = \sigma_* \sqrt{250} \quad (13)$$

在 KMV 模型的研究中, 有研究表明波动率这一参数在该模型中对于违约距离的影响最大, 因此目前的大多数研究采用 GARCH 模型来估计波动率, 然后带入 KMV 模型中计算出违约距离和违约概率, 但相关研究表明在对于波动率的拟合估计方面, SV 模型比 GARCH 模型的效果更好, 所以本文将 GARCH 模型和 SV 模型两者的估计效果进行对比, 再将其结合 KMV 模型来进行研究分析。

3.2. GARCH 模型

GARCH 模型于 1986 年由 Bollerslev 提出, 能够较好地刻画波动的时变特性。GARCH (1, 1)模型具体如下:

$$r_t = \mu + a_t, \quad a_t = \sqrt{h_t} \epsilon_t \quad (14)$$

$$h_t = \alpha_1 + \alpha_2 a_{t-1}^2 + \beta_1 h_{t-1} \quad (15)$$

其中 r_t 为对数收益率, ϵ_t 是均值为 0、方差为 1 的独立同分布随机变量序列, $\alpha_1 > 0$, $\alpha_2 \geq 0$, $\beta_1 \geq 0$, h_t 表示随时间变动的波动率。

3.3. SV 模型

1. 模型构建

随机波动率模型(SV 模型)始于 20 世纪 80 年代, 自 Jacquier, Polson 和 Rossi 在 1994 年首次提供二零随机波动性的明确证据以来开始适用。其具体如下:

$$r_t = \mu + a_t, \quad a_t = \sqrt{h_t} \epsilon_t \quad (16)$$

$$\ln h_t = \alpha_1 + \alpha_2 \ln h_{t-1} + v_t \quad (17)$$

其中 $\epsilon_t \sim N(0, 1)$, $v_t \sim N(0, \sigma_v^2)$, r_t 表示第 t 日的收益率, ϵ_t 为白噪声干扰; 误差项 ϵ_t 与 v_t 不相关。 α_2 为持续性参数, 反映当前波动对未来的影响, 并且 $|\alpha_2| < 1$; $\ln h_t$ 为潜在波动率。

2. 参数估计

从理论上来说, SV 模型的构建以及参数设定对于时间序列的波动估计效果比 GARCH 模型更好; 然而, 该模型存在着隐含波动率, 难以计算其似然函数, 使其估计比 GARCH 模型更具挑战性。

目前, SV 模型的参数估计方式一般分为: 伪极大似然估计(UML)、有效矩方式(EMM)估计以及马尔科夫链蒙特卡洛模拟(MCMC)方式等等。本文采用 MCMC 法对 SV 模型的所有参数进行预测, 该方法的基本思路是建立一种稳定分布为 $\pi(x)$ 的样本空间, 并在此基础上开展各种数据推断。其核心的算法在于从具有不变分布的马尔可夫链中重复抽样变量, 通过遍历性对变量进行估计。通过 MCMC 方法, 可以有效地估计给定多元概率密度的参数。该方法的运作依赖于反复从马尔可夫链中抽样, 以产生能够遍历变量的样本。通过这种方式, 可以对变量进行准确的估计。

本文将结合 MCMC 中的 Gibbs 抽样和 MH 算法来估计 SV 模型, 具体模拟过程通过 Matlab 实现。具体抽样步骤如下:

- (1) 初始化 H 和 Φ ;
- (2) 从 $\ln h_t | \ln h_{t-1}, R, \Phi, t = 1, \dots, n$ 中抽样;

(3) 抽样 $\sigma_v^2 | R, H, \alpha_1, \alpha_2$;

(4) 抽样 $\alpha_2 | H, \alpha_1, \sigma_v^2$;

(5) 抽样 $\alpha_1 | H, \alpha_2, \sigma_v^2$;

(6) 返回(2)。

其中 $H = (h_1, \dots, h_n)$, $\Phi = (\alpha_1, \alpha_2, \sigma_v^2)^n$, $R = (r_1, \dots, r_n)$ 。从步骤(2)到(5)循环 N 次, 去掉前 M 次作为“烧期数”, 得到 Ψ 的统计量 $\hat{\Psi}$:

$$\hat{\Psi} \approx \frac{1}{N-M} \sum_{i=M+1}^N \Psi^{(i)} \quad (18)$$

$\Psi^{(i)}$ 为第 i 次抽样的结果, 本文 N 选择 10,000 次, M 选择为 4000 次。

本文对未知参数的先验分布参考 Kim (1998): $\alpha_1 \sim N(0, 10)$, $\alpha_2 = 2\alpha_2^* - 1$, $\alpha_2^* \sim \text{Beta}(20, 15)$, $\sigma_v^2 \sim \text{IG}(2.5, 0.025)$ 。

其中 N 表示正态分布; Beta 表示贝塔分布, 则 α_2 的均值为 0.86, 方差为 0.016; IG 表示逆 Gamma 分布, 对应的均值为 0.167, 方差为 0.0236。

4. 实证研究

4.1. 样本选取与研究设计

本文选取 2021、2022 两年内一共 18 家公司, 其中 9 家 ST 公司和 9 家非 ST 公司, ST 公司为样本选取时间两年内一直戴帽的公司, 并且所选 ST 公司与非 ST 公司处于同一行业且规模相似, 来保证数据的有效性。本文所有数据选自 CSMAR 数据库。

首先, 计算出所选取的 18 家公司 2021~2022 年每日收盘价的对数收益率, 接下来, 利用历史数据计算了 18 家公司的股权价值波动率, 并使用 Matlab 计算出每家公司每年的资产价值和及其波动率。基于资产价值和波动率的计算, 结合公司各年的债务总计, 计算出各公司各年的违约距离。随后, 再分别运用 GARCH 模型和 SV 模型对股票收益波动率进行重新估计, 计算出两年的日波动率, 并按照每年 250 个交易日运用公式转换为年波动率。然后, 将这些年波动率带入 KMV 模型的公式中, 计算出公司资产的市值及其波动率, 进而计算出每家公司每年的违约距离。其中具体针对 SV 模型估计波动率的步骤如下: (1) 首先使用 Matlab 软件对 SV 模型的待估参数进行了 10,000 次迭代估计, 在此过程中, 本文舍弃了前 4000 次迭代, 最终得出各参数的均值; (2) 然后, 将 $\ln h_t$ 作为参数, 通过 Gibbs 抽样得到了 $\ln h_t$ 的估计序列。接着, 结合第(1)步估计的参数, 再将估计序列带入 SV 模型中计算出两年的日波动率, 再根据公式将其转化为年波动率。最后得出三个模型下 ST 公司与非 ST 公司的违约距离结果, 如表 1 所示。

两年内 GARCH-KMV 模型得到的违约距离对比如图 1、图 2 所示; SV-KMV 模型得到的违约距离对比如图 3、图 4 所示。

同时本文对两种模型下 18 家公司两年的违约距离分年分别进行了独立样本 T 检验和非参数 Mann-Whitney U 检验。具体结果如表 2 和表 3 所示。

4.2. 实证结果分析


(1) KMV 模型对波动率变化更为敏感。无论是 GARCH-KMV 还是 SV-KMV 模型在 2021 年和 2022 年得到波动率相关系数均为负值, 表明违约距离与波动率高度负相关, 即波动率越大, 违约距离越小, 上市公司的信用质量越差。

(2) SV 模型与 KMV 模型结合后对于上市公司信用风险的度量效果更为准确。根据表 1 中的数据,

Table 1. Calculation results of 18 companies**表 1.** 18 家公司计算结果

ST 公司					非 ST 公司				
证券代码	时间	DD	GDD	SDD	证券代码	时间	DD	GDD	SDD
600265	2021	3.03	2.47	2.32	000735	2021	3.97	4.00	4.68
	2022	2.78	2.79	2.73		2022	3.16	2.97	2.98
002052	2021	2.27	2.25	2.55	300625	2021	3.44	3.40	3.73
	2022	2.65	2.67	2.41		2022	3.05	3.09	4.19
002470	2021	1.94	1.93	1.58	300232	2021	2.70	2.74	3.00
	2022	2.67	2.82	3.34		2022	3.00	2.75	3.63
002535	2021	2.33	2.33	2.33	603725	2021	2.40	2.39	2.61
	2022	2.43	2.39	2.31		2022	2.58	2.44	3.52
002569	2021	2.88	2.92	3.55	603012	2021	4.09	4.10	4.71
	2022	3.24	3.23	3.42		2022	3.26	3.14	4.42
300029	2021	1.87	1.91	1.71	600768	2021	3.33	3.37	3.70
	2022	1.62	1.59	1.59		2022	2.26	2.45	3.38
002700	2021	3.07	3.09	4.40	000598	2021	3.88	3.56	3.49
	2022	2.89	2.92	4.00		2022	4.82	4.88	5.26
002872	2021	3.47	3.48	2.30	600648	2021	4.61	4.25	7.73
	2022	3.51	3.73	5.52		2022	3.80	3.40	5.80
600654	2021	2.73	2.76	1.82	300851	2021	2.70	2.72	3.77
	2022	2.11	2.16	2.31		2022	3.52	3.48	3.55

注：DD 为 KMV 模型的违约距离，GDD 为 GARCH-KMV 模型的违约距离，SDD 为 SV-KMV 模型的违约距离。

**Figure 1.** Default distance in 2021 (GARCH)**图 1.** 2021 年违约距离(GARCH)




Figure 2. Default distance in 2021 (SV)
图 2. 2021 年违约距离(SV)




Figure 3. Default distance in 2022 (GARCH)
图 3. 2022 年违约距离(GARCH)

Table 2. Independent sample T-test
表 2. 独立样本 T 检验

违约距离	DD		GDD		SDD	
时间	2021	2022	2021	2022	2021	2022
ST 均值	2.620	2.655	2.570	2.701	2.508	3.071
非 ST 均值	3.458	3.272	3.391	3.178	4.157	4.082
均值差	0.838	0.617	0.821	0.476	1.649	1.012
T 值	-2.718**	-1.984*	-2.894**	-1.488	-2.808**	-2.029*
P 值	0.015	0.065	0.011	0.156	0.013	0.059

注：***、**、*分别表示在 1%、5%和 10%水平显著。




Figure 4. Default distance in 2022 (SV)

图 4. 2022 年违约距离(SV)

Table 3. M-WU inspection

表 3. M-WU 检验

违约距离	DD		GDD		SDD	
时间	2021	2022	2021	2022	2021	2022
ST 秩均值	6.890	7.220	6.670	7.780	6.000	6.780
非 ST 秩均值	12.110	11.780	12.230	11.220	13.000	12.220
秩均值差	5.220	4.560	5.560	3.440	7.000	5.440
Z 值	2.075**	1.81*	2.252**	1.369	2.782***	2.163**
P 值	0.038	0.07	0.024	0.171	0.005	0.031

注：***、**、*分别表示在 1%、5%和 10%水平显著。

我们可以观察到 18 家上市公司在过去两年中的违约距离。根据违约距离越大说明信用质量越好这一理论，为便于比较，我们通常认为非 ST 公司违约距离比 ST 公司的违约距离更大，把相同年份、规模相近的 ST 公司和非 ST 公司分成一组进行比较，如果非 ST 公司违约距离比 ST 公司要小，则说明判断有误。首先，根据 KMV 模型计算出的违约距离发现，ST 公司的违约距离在 2021 年和 2022 年大于对应组内非 ST 公司的数量占总组数的比重分别为 88.89%和 100%，即正确率分别为 88.89%和 100%；而根据 GARCH 模型计算的违约距离来看，2021 年和 2022 年的准确率分别为 88.89%和 66.67%；根据 SV 模型计算的违约距离来看，两年的准确率分别为 88.89%和 100%。对比三种模型可以发现，上市公司的信用风险是可以有效衡量的，无论是传统的 KMV 模式，还是修正后的 KMV 模式。但相对于 GDD，DD 和 SDD 的精确度更高，能更好区别出 ST 公司和非 ST 公司的信用质量。这也表明，GARCH 模型在应用于 KMV 模型中并不如 SV 模型效果好，甚至不如传统 KMV 模型使用历史波动率效果好。

同样地，通过对图 1 和图 2、图 3 和图 4 的观察，SV 模型得到的违约距离更加明显地区分了 ST 公司和非 ST 公司的信用差异，特别是在图 3 中，2022 年的违约距离 GDD 曲线与 ST 公司曲线和非 ST 公司曲线有较多的交叉点。这也说明，在衡量上市公司信用质量时 SV-KMV 模型效果更好。

此外，通过表 2 和表 3 中 T 值和 Z 值也可以看出，SV 模型与 KMV 模型相结合情况下计算出的 ST

公司与非 ST 公司的违约距离差异明显性要大于 GARCH 模型与 KMV 模型相结合所得的违约距离。这表明 ST 公司与非 ST 公司在利用 SV 模型进行波动率估计时两者之间存在明显差异, 也表明 SV 模型得到的违约距离比 GARCH 模型得到的违约距离能更显著地区分上市公司的信用质量。根据表 2 和表 3 的均值差和秩均值差, 也可以得出结论: 两年内的 SV 模型得到的违约距离比 GARCH 模型得到的违约距离更大, 这说明 SV 模型与 KMV 模型相结合的模式在区分 ST 公司和非 ST 公司的信用质量方面更为显著, 进一步验证了 SV 模型的估计效果更好。

(3) 此外, 在进行行业比较时, 也呈现出上述结论相同的情况: 以电热燃气和水生产和供应行业为例, ST 浩源在 2021 年和 2022 年的 SDD 分别为 4.40 和 4.00, 而兴蓉环境的相应数值分别为 3.49 和 5.26。可见, 只有在 2021 年 ST 浩源的 SDD 高于兴蓉环境。观察股权价值波动率, 发现 2021 年 ST 浩源的值为 0.22, 低于兴蓉环境的 0.28。这也是导致两家公司判断错误的主要原因, 进一步说明了股权价值波动率在 KMV 模型中的重要性。

综合所选样本可以看出, 不同行业的违约距离存在差异, 但总体上符合理论预期: ST 公司的违约距离通常小于非 ST 公司的违约距离, 与实际情况较为吻合。

5. 结论

本文分别运用 SV 模型和 GARCH 模型与 KMV 模型相结合进行分析发现, 在 KMV 模型中, 股票收益波动率作为重要参数, 其对违约距离的贡献最大, 并且两者之间呈现出负相关关系, 即当波动率越大时, 违约距离越小, 这也说明该公司的信用质量也就越差。

同时, 无论是 GARCH 模型还是 SV 模型, 都可以通过对波动率的估计来提高 KMV 模型的精确度, 更好地衡量上市公司的信用质量。然而, 根据研究和检验结果来看, SV 模型与 KMV 模型相结合的模式相较于 GARCH 模型与 KMV 模型相结合的模式的效果更好, 能更好地区别开 ST 公司与非 ST 公司的信用质量差异。

因此, 股票收益波动率在 KMV 模型中有着重大影响。SV 模型通过对时间序列更准确地估计, 在结合 KMV 模型的情况下可以更准确地估计上市公司的资信质量, 说明 ST 公司与非 ST 公司的差异, 这对于 KMV 模型精确度的提升, 有着非同寻常的意义。

参考文献

- [1] Altman, E.I. (1968) Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, 23, 589-609. <https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>
- [2] Altman, E.I., Haldeman, R.G. and Narayanan, P. (1977) ZETA™ Analysis a New Model to Identify Bankruptcy Risk of Corporations. *Journal of Banking & Finance*, 1, 29-54. [https://doi.org/10.1016/0378-4266\(77\)90017-6](https://doi.org/10.1016/0378-4266(77)90017-6)
- [3] Bollerslev, T. (1986) Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 31, 307-327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- [4] Taylor, S.J. (1986) Modeling Financial Time Series. John Wiley and Sons.
- [5] Kim, S., Shepherd, N. and Chib, S. (1998) Stochastic Volatility: Likelihood Inference and Comparison with ARCH Models. *Review of Economic Studies*, 65, 361-393. <https://doi.org/10.1111/1467-937x.00050>
- [6] 蒋正权, 张能福. KMV 模型的修正及其应用[J]. 统计与决策, 2008(9): 67-69.
- [7] 周子元, 杨永生. 用违约距离判别信用风险: 一个实证研究[J]. 审计与经济研究, 2007(2): 81-85.
- [8] 王莉. 引入违约距离的修正 KMV 模型在财务危机预警中的应用[J]. 统计与决策, 2017(17): 88-91.
- [9] 杨柳勇, 王礼月. 行业与区域视角下的债券信用风险度量——基于 LJD-KMV 模型的实证研究[J]. 财会月刊, 2018(14): 155-161.
- [10] 段翀. 基于 PFM 模型与倾向匹配得分法的中小企业信用风险评估[J]. 征信, 2020, 38(6): 35-42.
- [11] 孙亮, 吕丹妮. 我国共享经济企业信用风险度量的案例分析——基于 KMV 修正模型的实证研究[J]. 技术经济,

- 2021, 40(6): 132-139.
- [12] 郭立仑, 周升起. 商业银行信用风险主要影响因素来自内部还是外部?——基于 KMV 及随机森林模型的实证研究[J]. 会计与经济研究, 2022, 36(1): 105-124.
- [13] 蔡真, 林菁, 薄栋. 房地产调控与房企违约风险——基于 KMV 模型和面板回归的分析[J]. 重庆邮电大学学报(社会科学版), 2023, 35(5): 115-127.
- [14] 凌华, 周会洋, 沈云, 等. 地方政府专项债券的风险测度与预警研究[J]. 会计之友, 2021(4): 61-67.
- [15] 张慧, 王宁, 孟纹羽. 基于分形 KMV 模型的地方政府债券安全发行规模测度[J]. 统计与决策, 2021, 37(15): 133-136.
- [16] 李绍荣, 刘星洋. 城投债信用风险的压力测试: 基于优化后的 KMV 模型[J]. 新视野, 2023(6): 79-87.
- [17] 余素红, 张世英. SV 与 GARCH 模型对金融时间序列刻画能力的比较研究[J]. 系统工程, 2002, 20(5): 28-33.
- [18] 余素红, 张世英. SV 和 GARCH 模型拟合优度比较的似然比检验[J]. 系统工程学报, 2004, 19(6): 625-629.