

文章编号: 1674-8085(2020)05-0010-08

基于动态 R-Vine Copula 的银行股指投资组合及风险度量研究

*徐刚刚, 狄千姿, 石 慧

(新疆农业大学数理学院, 新疆, 乌鲁木齐 830052)

摘 要: 金融资产价格之间的波动往往具有结构相依性。为了研究银行股指数据间这种复杂关系, 能够进一步准确度量金融风险, 本文以我国六大银行股指数据为研究对象, 利用 ARMA-GJR-SkT 模型作为单一资产序列的边缘分布, 以灵活的 R-Vine Copula 模型为基础, 联合构建投资组合模型。通过滚动时间窗口的 Monte Carlo 技术及 MST-PRIM 算法确定各类模型的 RVM 结构, 在此基础上结合逆变换法仿真模拟收益率序列, 并利用模拟收益率进一步计算 VaR 与 CVaR, 最后经返回值检验法对模型进行验证。结果表明: 建立最优的投资组合模型是精准度量金融风险的关键; 在风险度量时, 相同的置信水平下, CVaR 模型比 VaR 模型更可靠。置信水平不等时, 其值增大的同时, 失败天数会减小。

关键词: 动态 R-Vine Copula 模型; Monte Carlo 模拟; CVaR; MST-PRIM 算法

中图分类号: F830.59

文献标识码: A

DOI:10.3969/j.issn.1674-8085.2020.05.003

RESEARCH ON BANK STOCK INDEX PORTFOLIO AND RISK MEASUREMENT BASED ON DYNAMIC R-VINE COPULA

*XU Gang-gang, DI Qian-zi, SHI Hui

(College of Mathematics and Physics, Xinjiang Agricultural University, Urumuqi, xinjiang 830052, China)

Abstract: The fluctuation of financial asset prices often has structural dependence. In order to study the complex relationship between banking stock index data and further accurately measure the financial risk, this paper takes the six major stock index data of China's banking as the research object, Using arma-gjr-skt as the marginal distribution of a single asset sequence, Based on the flexible r-vine copula model, jointly build the portfolio model. The RVM structure of various models is determined by the Monte Carlo technique of rolling time window and mst-prim algorithm. On this basis, the return sequence is simulated by inverse transformation method, and the VaR and CVaR are further calculated by the simulated return rate. Finally, the model is verified by back-testing method. The results show that the establishment of the optimal portfolio model is the key to accurately measure the financial risk. Given the same level of confidence in risk measurement, CVaR model is more reliable than VaR model. When the confidence level is different, the number of failure days will decrease as the value increases.

Key words: dynamic R-Vine Copula model; Monte Carlo simulation; CVaR; MST-PRIM algorithm

收稿日期: 2020-05-06; 修改日期: 2020-06-17

基金项目: 新疆维吾尔自治区高校科研项目(XJEDU2018Y021);新疆农业大学大学生创新创业计划训练项目(dxscx2020518)

作者简介: *徐刚刚(1989-), 男, 甘肃平凉人, 助教, 硕士生, 主要从事数理统计与金融统计研究(E-Mail:907252735@qq.com);

狄千姿(1999-), 女, 新疆乌鲁木齐人, 新疆农业大学数理学院 2018 级本科生(E-Mail:1602857468@qq.com);

石 慧(2000-), 女, 重庆人, 新疆农业大学数理学院 2018 级本科生(E-Mail:2190212874@qq.com).

0 引言

随着金融市场一体化、全球化发展, 银行股指数数据间的波动通常具有跨地区的相依性, 同时伴随着银行业系统性风险的出现, 而精准度量这种风险的关键在于构建资产间的投资组合模型。众多学者^[1-5]将目光投放到 Copula 函数的研究上, Copula 被引入到金融领域中广泛应用的同时, 其自身也得到了迅速的发展。自从 Embrechts 等^[6]利用 Copula 函数分析金融数据以来, 无论从维数上, 还是动态时变性方面都得到了进一步扩展。比如 Patton 等^[7]利用动态 Copula 模型分析了国际外汇市场的动态相关性; 李平等^[8]通过建立 Copula 模型, 进一步模拟或有可转换债券(CoCo)定价, 并在此模型的基础上数值分析; 葛亮^[9]采用 Copula-GARCH 模型对上证交易所新兴产业指数与上证综合指数构建五个二元 Copula 模型, 并用 GOD 模型对数据尾部进行分析, 事实证明: 极端情形下两指数的涨跌幅度较大; 吴鑫育等^[10]通过构建随机 Copula 模型来研究中国股市量价间的尾部相关性, 最终结果表明: 中国股市量价尾部相关性展现明显的动态特征; 鲁思瑶等^[11]针对 2015 年股灾和 2016 年熔断期间的上证综、中证综合债以及上证基金间的相关性, 通过利用扭曲混合 Copula 和 RAMA-GARCH-T 模型实证分析, 研究表明: 扭曲混合 Copula 模型较混合 Copula 模型能更好地拟合各资产日收益率间的相关结构; 许可等^[12]采用混合 Copula 函数刻画银行业间的复杂相关性, 进一步度量商业银行面临的主要风险; 韩超等^[13]采用 R-Vine Copula 模型解决股份制商业银行系统性风险精准度量问题, 并以历史重现原则仿真 VaR, 为金融风险管理研究者提供了风险度量的量化方法。银行业股指数数据间的传染性往往会影响到其投资组合风险度量的准确性, 因此构建合理的银行股指数数据间的投资组合模型, 能够为进一步精准度量银行系统性风险提供可靠的理论支撑。

银行业系统性风险度量是近年来学者们^[14-16]所青睐的热点之一, 目前应用较多的是风险价值(VaR)、条件风险价值(CVaR)以及 Mean-CVaR。

例如, 叶莉等^[17]基于 CoVaR 方法对我国商业银行系统性风险溢出效应进行分析, 研究结果表明: 过去十年间, 从宏观和微观两个层面比较分析了银行之间的溢出效应与风险传染方向; 翁志超等^[18]以商业银行指数和互联网金融指数收盘价数据为研究样本, 建立了 GARCG-Copula-CoVaR 模型来度量互联网金融对商业银行的系统性风险溢出效应, 得出了互联网金融对不同类型商业银行的系统性风险溢出具有异质性结论。上述文献均从静态的角度讨论了金融风险特性, 但对序列数据的动态波动特点并未做过多研究, 而金融序列数据的时变性已经是一个不可忽视的研究课题。

因此, 本文从序列波动的动态方面出发, 利用滚动时间窗口的 Monte Carlo 技术进行仿真模拟, 最终得到每日的 VaR 以及 CVaR 预测值。在上述文献的基础上, 从下面几个方面进行研究: 首先, 选取我国具有代表性的六大银行股指数数据为研究对象, 利用 ARMA-GJR-SkT 模型作为边缘分布, 通过对单一资产序列进行拟合, 充分解释了金融序列非对称性以及 ARCH 效应等方面的分布特征; 其次, 利用 R-Vine Copula 模型连接各边缘分布, 由于 R-Vine 结构在选择 pair-Copula 函数时具有其独特的灵活性, 因此经过最大生成树(MST-PRIM)算法得到最优的藤结构, 使投资组合模型更加合理; 另外, 本文整个过程采用滚动时间窗口的 Monte Carlo 模拟技术完成, 故在仿真模拟以及 VaR 和 CVaR 的计算上遵从动态的时变性原则; 最后, 通过理论成熟的 Kupiec 检验完成了模型验证, 分别选 95%和 99%的置信水平, 对比讨论了 VaR 与 CVaR 的在度量金融风险上的优点和不足。

1 模型的构建

1.1 边缘分布

由于股票收益率序列往往具有非对称性及“尖峰厚尾”等分布特征, 因此本文选择具有偏学生 t 分布的 ARMA(p,q)-GJR(1,1)-SkT 模型作为边缘分布进行刻画序列的这些特性。具体公式为

$$r_t = \mu + \sum_{i=1}^p \phi_i r_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t, \varepsilon_t = \sigma_t z_t,$$

$$\sigma_t^2 = \omega + \alpha \sigma_{t-1}^2 + \beta \varepsilon_{t-1}^2 + \gamma \varepsilon_{t-1}^2 I_{t-1} \{\varepsilon_{t-1} < 0\},$$

$$z_t \sim i.i.d. SkT(v, \lambda)$$

其中, $\omega > 0$, $\alpha, \beta \geq 0$, $\alpha + \gamma \geq 0$, $I_{t-1} \{\varepsilon_{t-1} < 0\}$ 为示性函数。 $SkT(v, \lambda)$ 表示自由度为 v , 偏度为 λ 的偏学生 t 分布, 具体为

$$F(x; v, \lambda) = \begin{cases} (1-\lambda)T\left[\frac{bx+a}{1-\lambda}\left(\frac{v}{v-2}\right)^{1/2}; v\right], & x < -\frac{a}{b}, \\ (1+\lambda)T\left[\frac{bx+a}{1-\lambda}\left(\frac{v}{v+2}\right)^{1/2}; v\right], & x \geq -\frac{a}{b}. \end{cases}$$

其中,

$$f(x) = \prod_{k=1}^n f_k(x_k) \prod_{k=1}^{n-1} \prod_{i=k+1}^n c_{m_{k,k}, m_{i,k} | m_{i+1,k}, \dots, m_{n,k}} \left(F_{m_{k,k} | m_{i+1,k}, \dots, m_{n,k}}, F_{m_{i,k} | m_{i+1,k}, \dots, m_{n,k}} \right)$$

其中, $F(\cdot)$ 为各随机向量的边缘分布; $f(\cdot)$ 为对应的密度函数; $c(\cdot)$ 为每条边上连接两个节点的 Copula 函数, 称为 pair-Copula 函数。一个 n 维 R-Vine 结构共有 $n-1$ 棵树, n 个节点以及 $n(n-1)/2$ 条边构成。

R-Vine Copula 模型的参数估计采用极大似然估计法, 具体步骤为: 首先根据最大生成树 MST-PRIM 算法^[23]来选择 R-Vine 结构, 然后利用赤池信息准则(AIC)以及贝叶斯信息准则(BIC)确定 Pair-Copula 函数, 最后通过极大似然估计法估计出所有的未知参数。AIC 与 BIC 的具体计算公式为

$$AIC_{\hat{\theta}_{i,j}} = -2 \sum_{i=1}^n \ln f(x_{i,j} | \hat{\theta}_{i,j}) + 2k,$$

$$BIC_{\hat{\theta}_{i,j}} = -2 \sum_{i=1}^n \ln f(x_{i,j} | \hat{\theta}_{i,j}) + k \ln(n)$$

其中, $\hat{\theta}_{i,j}$ 为节点集 i 与 j 之间 Pair-Copula 函数的参数估计值, k 为参数组的个数。

1.3 仿真模拟及模型预测

风险价值(VaR)是指在一定时期内, 给定的置信水平 $1-\alpha \in (0,1)$ 下, 投资组合面临的最大损失。公式为

$$VaR_t(1-\alpha) = -F_{X_t}(\alpha)$$

其中, $F_{X_t}(\cdot)$ 为组合收益率 X_t 的累积分布函数, $X_{i,t}$ 表示第 i 个资产价值在 t 时刻的损益, 本文中

$$a = 4\lambda c \frac{v-2}{v-1}, \quad b^2 = 1 + 3\lambda^2 - a^2, \quad c = \frac{\Gamma((v+1)/2)}{\Gamma(v/2)\sqrt{\pi(v-2)}},$$

$\lambda \in (-1,1)$, $v \in (2, +\infty)$, $T(\cdot; v)$ 是 t 分布函数。

1.2 R-Vine Copula 模型与参数估计

精准度量金融风险的关键在于构建合理的投资组合模型, 在各类 Vine Copula 模型中, R-Vine Copula 在选择 pair-Copula 函数时更灵活, 刻画金融序列的复杂相依性时优越性更强, 因此本文以 R-Vine Copula 来建立投资组合模型。考虑到该模型比较复杂, 这里采用 R-Vine 矩阵法(RVM)^[19-22]来表示其结构, 一个 n 维 R-Vine Copula 模型联合密度形式为

投资组合收益率表示为

$$X_t = \sum_{i=1}^n \omega_i X_{i,t}$$

其中 ω_i 表示资产 X_i 在组合中的权重。

由于组合的 VaR 可能超过组合中各资产的加权平均 VaR, 因此, 通常也用具有次可加性 CVaR 来度量组合的风险。CVaR 衡量了一定置信水平 $1-\alpha \in (0,1)$ 下发生损失超过 VaR 的平均损失, 公式为

$$CVaR_t(1-\alpha) = E[X_t | X_t \leq -VaR_t(1-\alpha)] = -\frac{\int_{-\infty}^{-VaR_t} z f_{X_t}(z) dz}{F_{X_t}(-VaR_t(1-\alpha))} = -\frac{\int_{-\infty}^{-VaR_t} z f_{X_t}(z) dz}{\alpha}$$

其中, $f_{X_t}(\cdot)$ 为组合收益率 X_t 的概率密度函数。

为了有效验证银行业金融市场波动的时变特点, 采用具有动态性的滚动时间窗口 Monte Carlo 技术^[20]进行仿真模拟并预测, 具体做法如下:

(1) 将样本数据 $\{D: t=1, 2, \dots, 1686\}$ 分成“训练样本集”与“测试样本集”两部分, 后 300 个交易日为预测样本区间, 紧挨每个预测样本前面的 1368 个交易日数据为训练样本;

(2) 对于样本数据 $\{D_1: t=1, 2, \dots, 1386\}$, 利用边缘分布 ARMA-GJR-SkT 模型将单一序列进行过滤, 并将所得到的标准化残差序列进一步概率积分化变换(PIT), 则得到第二阶段 R-Vine Copula

拟合所需的均匀分布序列;

(3)利用 R-Vine Copula 模型对变换之后的序列的建模。根据最大生成树(MST-PRIM)算法选择合理的 R-Vine 结构,然后在 AIC 和 BIC 信息准则下选出每个节点间的 Pair-Copula 函数,于是最优 R-Vine Copula 模型就得以确定;其次利用极大似然估计法求出每个 Pair-Copula 函数中的所有参数,并以所得模型仿真模拟出 1000 个随机数组,最后对该随机数组利用逆变换法算出服从偏学生 t 分布的随机数组 $(z_1, \dots, z_6)$,将该随机数组作为第 1387 日的分布数组;

(4)由公式 $X_{t,i} = \hat{\mu}_i + \hat{\sigma}_{t,i} z_{t,i}, i=1, \dots, 6$ 反推模拟收益率 $X_{t,i}$,其中 $\hat{\mu}_i$ 与 $\hat{\sigma}_{t,i}$ 分别为边缘分布中第 i 个序列第 t 日的均值方程系数和标准差的估计值。通过公式 $\sum_{i=1}^6 \omega_i X_{t,i}$ 计算投资组合收益率,最后得到第 t 日(第 1387 日)的 VaR 与 CVaR 预测值;

(5)在样本量恒定为 1386 的情况下,将样本区间向后推一天,再进行(2)~(4)过程就可以得到第 $t+1$ 日(第 1388 日)的 VaR 与 CVaR 预测值;

(6)反复进行步骤(5),可以计算出第 1389, 1390 直到第 1686 日的 VaR 与 CVaR 值,即得到样本外 300 天的投资组合 VaR 与 CVaR。

1.4 模型检验

这里选择 Kupiec 检验^[24]来验证模型的预测效果,即假设给定显著性水平为 α ,实际考察天数为 T ,总失败天数为 N ,检验的原假设 $H_0: N/T = 1 - \alpha$,似然比检验统计量为 $L = -2 \ln((1 - \alpha)^N \alpha^{T-N}) + 2 \ln((N/T)^N (1 - N/T)^{T-N})$,在原假设 H_0 成立的条件下 $L \sim \chi^2(1)$ 。

2 实证分析

2.1 数据说明与处理

本文选取中国银行(ZH)、工商银行(GH)、建设银行(JH)、恒生银行(HS)、平安银行(PA)以及招商银行(ZS)六大银行股票日收盘价数据,日期从 2012 年 12 月 3 日至 2020 年 4 月 8 日,数据来源于 WIND 数据库。删除交易日不重叠部分,经过公式 $X_{t,i} = 100 \times \ln(P_{t,i} / P_{t-1,i})$ 计算得到 1686 个日收益率数据作为研究样本,其中 $P_{t,i}$ 表示第 i 支股票在第 t 日的收盘价。将所有样本数据分为 1386 组样本内和 300 组样本外数据,样本内数据用于建模,样本外数据进行检验模型的预测效果,整篇论文在 R 语言的帮助下完成。




图 1 六支股票指数收益率波动图
Fig.1 Volatility chart of six stock indexes

图 1 为六支股票收益率序列波动图,从图中可以很明显看出:前 4 支序列的波动幅度整体较小,而平安银行(PA)和招商银行(ZS)股指收益率序列波动幅度较大;除了金融序列固有的“典型特征”之外,不同的序列数据在相同的时间段波动趋势极其相似,说明序列之间还存在复杂的相依关系,因此选择 GARCH 族以及 Vine Copula 模型刻画它们之间的分布特征显得很有意义。

2.2 数据分析与参数估计

为了进一步量化分析收益率数据的分布情况,这里首先对其进行描述统计分析,结果如表 1 所示。由结果可得:各序列的偏度均大于 0,峰度大于 3,具有典型的“尖峰厚尾”、右偏特征,说明股票收盘价整体呈现上涨趋势,并且不适合用正态分布去拟合,J-B 检验也充分证实了这一结论。另外由各阶滞后的 LM 检验结果显示:各序列检验统计量对应的 P 值都小于 0,拒绝原假设,即认为各序列存在明显的 ARCH 效应。综合以上分析:选取具有时变性、动态性及非对称性的 ARMA-GJR-SkT 模型作为序列的边缘分布颇为恰当。

由于本文采用能够体现动态与时变特性的滚动时间窗口 Monte Carlo 模拟法进行参数估计与仿真模拟,在滚动计算过程中共进行了 300 次建模,每次建模所选择的样本数据都不同。因此这里只给出了首次滚动的 ARMA-GJR-SkT 模型的参数估计及检验结果,具体如表 2 所示。

表 1 原始数据的描述性统计分析结果

Table 1 Descriptive statistical analysis results of original data

	ZH	GH	JH	HS	PA	ZS
$Mean \times 10^{-3}$	-4.52	0.71	3.84	8.90	39.74	51.68
Std	1.58	1.64	1.65	1.17	2.43	2.04
Skewness	0.24	0.04	0.12	0.03	0.11	0.82
Kurtosis	7.02	4.15	5.99	4.93	11.09	10.04
J-B	3450.9 (0.000)	1198.3 (0.000)	2505.9 (0.000)	1692.2 (0.000)	8581.1 (0.000)	7224 (0.000)
LM(5)	42.48 (0.000)	51.19 (0.000)	39.97 (0.000)	76.37 (0.000)	107.68 (0.000)	16.07 (0.007)
LM(10)	50.52 (0.000)	64.48 (0.000)	47.06 (0.000)	112.39 (0.000)	113.59 (0.000)	22.98 (0.010)
LM(15)	54.77 (0.000)	68.27 (0.000)	48.09 (0.000)	114.07 (0.000)	117.25 (0.000)	27.12 (0.027)

注:括号内为 J-B 统计量和 L-M 统计量对应的 P 值

表 2 各序列边缘分布模型 ARMA(1,1)-GJR(1,1)-SkT 参数估计结果

Table 2 Parameter estimation results of ARMA (1,1) - GJR (1,1) - SKT for each sequence edge distribution model

参数	ZH	GH	JH	HS	PA	ZS
$\mu \times 10^{-3}$	8.15	1.22	5.54	45.26*	15.82	69.87
Ar1	-0.72***	-0.83***	0.91***	-0.84***	0.99***	-0.68***
Ma1	0.75***	0.85***	-0.92***	0.84***	-0.99***	0.77***
ω	0.17***	0.24**	0.23**	0.09**	0.01	0.06***
α	0.06**	0.02	0.02	0.05*	0.05***	0.02***
β	0.85***	0.85***	0.86***	0.83***	0.96***	0.96***
γ	0.04*	0.09***	0.06**	0.11*	-0.03***	0.01*
λ	1.01***	0.99***	0.99***	0.99***	1.08***	1.09***
ν	6.49***	5.36***	5.36***	4.17***	3.43***	4.79***
LL	-2515.06	-2566.79	-3120.00	-1922.53	-2818.94	-2817.64
K-S	0.504***	0.508***	0.500***	0.491***	0.512***	0.525***
LM(3)	0.39 (0.5325)	1.18 (0.2773)	0.3741 (0.5408)	0.8702 (0.3509)	1.866 (0.1720)	0.008 (0.9285)

注: LL 为模型估计的对数似然值,“***, **, *”表示在 1%, 5%, 10%的水平下显著, LM(3)为 ARCH 效应检验,括号中的数字对应检验统计量的 P 值

由表 2 结果可得:除均值之外,大部分参数在 1%的显著性水平下均显著,模型整体也通过了检验。对原序列的 K-S 检验结果表明:原序列在 5%的显著性水平下均显著,即认为概率积分化处理之后的残差序列服从 0-1 均匀分布。LM(3) 检验对应的 P 值均大于给定的显著性水平 5%,可以认为残差序列的波动不存在 ARCH 效应,从而进一步体现了 ARMA-GJR-SkT 模型作为边缘分布的合理性。

通过最大生成树(MST-PRIM)算法、极大似然估计以及各信息准则的计算,最终确定了每次滚动中的最优模型。与边缘分布一样,表 3 仅给出了 R-Vine 首次滚动的 RVM 结构中每条边上的 Pair-Copula 函数以及相应的节点排序情况。为了

方便, 将 1、2、3、4、5、6 分别表示 ZH、GH、JH、HS、PA 以及 ZS。其中树 1 中的节点为(6,4)、(3,1)、(3,2)、(6,3)与(6,5)。对应的 Pair-Copula 函数为 SBB1、T、T、SBB1、SBB1, 同理, 其余树的节点和 Pair-Copula 函数也可以由表 3 的计算结果得出。 τ 为 kendall 秩相关系数, 反映两组数据间的非线性变化关系, 比如树 1 中 GH(2)与 JH(3)间的 kendall 秩相关系数为 0.68, 大于 0.5, 表明工行股指收盘价与建行收盘价涨跌情况很相似。Ltd 与 Utd 分别表示序列间下尾与上尾相关系数, 反映两组数据的尾部相依性, 例如树 2 中“2,1;3”对应的 Ltd 与 Utd 均为 0.11, 表示在给定建行股指的条件下, 中行股指与建行股指序列间存在对称的尾部相关性。其余可进行类似分析, 此处不再赘述。

表 3 R-Vine 首次滚动的 RVM 结构的参数估计及检验结果

Table 3 Parameter estimation and test results of RVM							
structure with R-vine first rolling							
Tree	树结构	Copula	参数 1	参数 2	τ	Ltd	Utd
1	6,4	SBB1	0.15	1.28	0.27	0.28	0.03
	3,1	T	0.85	4.93	0.64	0.51	0.51
	3,2	T	0.88	4.42	0.68	0.58	0.58
	6,3	SBB1	0.40	1.34	0.38	0.32	0.28
	6,5	SBB1	0.30	1.34	0.35	0.32	0.18
2	3,4;6	T	0.15	11.08	0.09	0.01	0.01
	2,1;3	T	0.40	6.48	0.26	0.11	0.11
	6,2;3	SBB7	1.06	0.15	0.10	0.08	0.01
	5,3;6	F	1.09	0	0.12	—	—
	2,4;3,6	F	0.27	0	0.03	—	—
3	6,1;2,3	J	1.07	0	0.04	—	0.09
	5,2;6,3	SC	0.09	0	0.04	—	0
	1,4;2,3,6	I	—	—	0	—	—
4	5,1;6,2,3	F	0.24	0	0.03	—	—
	5,4;1,2,3,6	I	—	—	0	—	—
Type: R-Vine			LogLik: 2811.01	AIC: -5580.01	BIC: -5470.08		

为了更直观看到 R-Vine 首次滚动的 RVM 结构, 这里给出了 RVM 结构图, 同样 1、2、3、4、5、6 分别表示 ZH、GH、JH、HS、PA 以及 ZS, 图 2 与表 3 中的树结构完全吻合。




图 2 R-Vine 首次滚动的 RVM 结构图

Fig.2 RVM structure chart of R-vine's first rolling

2.3 风险度量与模型检验

建立合理的投资组合模型, 其目的在于精准地度量金融风险。度量金融风险的方法有很多, 本文选择风险价值 (VaR) 以及条件风险价值 (CVaR) 来实现模型的预测效果。计算投资组合 VaR 时, 本文通过 Monte Carlo 模拟技术, 结合逆变换法反推得到仿真模拟的日收益率数据, 在给定置信水平为 95% 与 99% 时分别求得 VaR 值, 然后通过与原始投资组合收益率相比, 进而得出总失败天数, 最后通过 Kupiec 检验得出相应的统计值与 P 值, 具体结果见表 4。

表 4 R-Vine Copula 模型 VaR 预测效果及 Kupiec 检验结果

Table 4 VaR prediction effect of R-vine copula model and kupiec test results						
Vine-Copula	95%置信水平 VaR			99%置信水平 VaR		
	N	N/T	L	N	N/T	L
R-Vine-Copula	14	0.047	0.072 (0.79)	4	0.013	0.305 (0.580)

由于组合的 VaR 可能超过组合中各资产的加权平均 VaR, 因此, 本文利用具有次可加性的 CVaR 来进一步度量组合的风险, 具体如表 5 所示。

表 5 R-vine Copula 模型 CVaR 预测效果及 Kupiec 检验结果

Table 5 CVaR prediction effect of R-vine copula model and kupiec test results

Vine-Copula	95%置信水平 CVaR			99%置信水平 CVaR		
	N	N/T	L	N	N/T	L
R-Vine-Copula	22	0.073	3.025 (0.082)	8	0.027	5.778 (0.016)

由表 4 和表 5 可得:无论在 95%还是在 99% 的置信水平下, VaR 与 CVaR 的 Kupiec 检验结果对应的 P 值均大于各自的显著性水平,因此没有理由拒绝原假设,即认为模型预测精准,拟合较合理;其次,从两个表中可以明显看出:随着置信水平的增大,风险价值减小,即失败天数随着置信水平的增大而减小;另外,在相同的置信水平下, CVaR 预测结果整体高于 VaR,而 CVaR 反映了一定置信水平下发生损失超过 VaR 的平均损失,因此在风险度量时显得更加可靠。图 3 更清楚地反映了两种置信水平下的 CVaR 预测结果。




图 3 不同置信水平下的 CVaR 与原序列投资组合收益率对比图

Fig.3 Comparison chart of CVaR and original portfolio return under different confidence levels

3 结论

选取六大银行业股票收盘价数据作为研究样本,经计算得到的各序列收益率数据不仅表现出明显的金融数据的“典型特征”,还具有复杂的相依性和波动的动态时变性。本文以 ARMA(1,1)-GJR(1,1)-SKT 模型作为边缘分布,以灵活的

R-Vine Copula 模型为基础,联合建立了投资组合模型,通过滚动时间窗口的 Monte Carlo 模拟技术进行仿真模拟,从静态的低维研究上升到高维的动态研究,在理论和实际操作上都有了进一步突破。

在六大银行股指序列的风险度量方面,本文不仅采用动态 VaR 模型进行预测,还选用 CVaR 模型做进一步预测,通过两种预测结果对比得出:在相同的置信水平下, CVaR 在风险度量时更加可靠,比 VaR 模型更具稳健性;置信水平不等时,随着置信水平的增大,风险价值减小,即失败天数减少。

参考文献:

- [1] Chen P, Zeng W L, Chen M, et al. Modeling arterial travel time distribution by accounting for link correlations: a copula-based approach [J]. Journal of Intelligent Transportation Systems, 2019, 23(1): 879-890.
- [2] Lyes K. Extreme Risk Modeling: An EVT-pair-Copulas Approach for Financial Stress Tests[J]. Journal of Banking and Finance, 2016 (70): 3-12.
- [3] 谢赤,李洪琼.金砖国家股指期货市场的相关结构及谱风险度量——基于 Vine-Copula 模型的实证研究[J]. 金融理论与实践, 2019(6): 1-8.
- [4] 韩超,周兵.高维动态藤 Copula 函数建模、仿真及在金融风险研究中的应用[J].数学的实践与认识, 2019, 49(12): 16-20.
- [5] 韩超,严太华.基于高维动态藤 Copula 的汇率组合风险分析[J].中国管理科学, 2017, 25(2): 10-20.
- [6] Embrechts P, McNeil A, Straumann D. Correlation: Pitfalls and alternatives [J]. RISK, 1999, 12(5): 69-70.
- [7] Patton Andrew J. Modeling asymmetries changes rate dependence [J]. International Economic Review, 2006, 47(2): 527-554.
- [8] 李平,尹菁华,来娜,等.基于 Copula 双变量模拟的 CoCo 债券定价 [J]. 系统工程学报, 2016, 31(6): 772-782.
- [9] 葛亮.基于 Copula-GARCH 模型的新兴产业与上证指数相依性研究[J].统计与决策, 2016(24): 170-173.
- [10] 吴鑫育,李心丹.中国股市量价尾部相关性研究——基于随机 copula 模型的实证 [J]. 金融理论与实

- 践,2017(1):93-97.
- [11] 鲁思瑶,徐美萍.基于扭曲混合 Copula 和 ARMA-GARCH-t 模型的投资组合风险分析——以上证综指、中证综合债和上证基金为例[J].数理统计与管理,2017,36(6):1131-1140.
- [12] 许可,刘亚南,张峰.基于混合 Copula 的商业银行整合风险度量研究[J].商场现代化,2017(7):146-147.
- [13] 韩超,周兵,熊亚.基于高维动态 R-Vine Copula 的股份制商业银行系统性金融风险计量研究[J].数学的实践与认识,2019,49(16):306-314.
- [14] Matthew G N, Viet H N, Barry R. Risk and return spill-overs among the G10 currencies[J]. Journal of Financial Markets, 2016, 31: 43-62.
- [15] 黄冬阳,宋光辉,董永琦.股票市场风险测度方法:文献综述[J].财会月刊,2019(3):147-158.
- [16] 李荣,刘露.Mean-CVaR 准则下延期支付供应链决策与协调[J].系统工程学报,2017,32(3):370-384.
- [17] 叶莉,李园丰,王远哲.基于 CoVaR 方法的我国商业银行系统性风险溢出效应测度[J].河北工业大学学报,2019,48(5):81-90.
- [18] 翁志超,颜美玲.互联网金融对商业银行的系统性风险溢出效应测度[J].统计与决策,2019,35(22):159-163.
- [19] 谢赤,李洪琼.金砖国家股指期货市场的相关结构及谱风险度量——基于 Vine-Copula 模型的实证研究[J].金融理论与实践,2019(6):1-8.
- [20] 林宇,梁州,林子泉,等.基于高维 R-vine Copula 的金融市场投资组合优化研究[J].系统工程理论与实践,2019,39(12):3061-3072.
- [21] 谢敏,胡昕彤,柯少佳,等.基于 vine-Copula 的发电商运营损益动态风险 VaR 评估方法[J].电力系统自动化,2019,43(5):39-45,52.
- [22] 朱鹏飞,唐勇,张仁坤.国际主要股票市场联动性——基于藤 Copula-HAR-RV 模型[J].系统工程,2018,36(9):16-29.
- [23] Xiong F, Jun L I. Network Resource Risk Forecast Based on Vine Copula-GARCH Model[J]. Journal of Hubei University of Technology, 2016, 31(5): 68-71.
- [24] Kupiec P. Techniques for verifying the accuracy of risk measurement models [J]. Journal of Derivatives, 1995,3(2): 173-184.