

DOI:10.19322/j.cnki.issn.1006-4710.2021.04.018

证券市场波动率分析的 PSO-ICA-GARCH 模型

周晓玲, 王小侠

(西安理工大学 理学院, 陕西 西安 710054)

摘要: 当主成分存在条件相关时, 正交广义自回归条件异方差模型(orthogonal generalized autoregressive conditional heteroskedasticity, O-GARCH)可能导致预测结果与实际情况不相符。基于独立分量分析的广义自回归条件异方差模型(GARCH model based on independent component analysis, ICA-GARCH)能有效解决此问题, 但 ICA-GARCH 模型中的梯度下降算法易陷入局部最优, 收敛精度也有待提高。为克服此缺点, 本文提出了一种基于粒子群优化算法的 ICA-GARCH 模型(ICA-GARCH model based on particle swarm optimization, PSO-ICA-GARCH), 并将其用于证券市场收益波动率建模, 以最终提高收益率预测效果。通过对阿里巴巴概念股收益波动率的实证分析, 结果显示 PSO-ICA-GARCH 模型相较于 O-GARCH 和 ICA-GARCH 模型, 具有更高的分离精度和更准确的模型预测效果。

关键词: 证券市场波动率; 独立分量分析; 粒子群算法; GARCH 模型

中图分类号: F832.48

文献标志码: A

文章编号: 1006-4710(2021)04-0595-08

PSO-ICA-GARCH model for volatility analysis of stock market

ZHOU Xiaoling, WANG Xiaoxia

(Faculty of Sciences, Xi'an University of Technology, Xi'an 710054, China)

Abstract: The principal components being conditional correlated, the orthogonal generalized autoregressive conditional heteroskedasticity model (O-GARCH) may lead to inconsistent predictions in the actual situation. GARCH based on independent component analysis (ICA-GARCH) can effectively solve that problem. However, the gradient descent algorithms for traditional ICA-GARCH models often get into a local extreme rather than the best one. In addition, their convergence accuracy could be improved. This paper proposed a GARCH model based on the particle swarm optimization and independent component analysis (PSO-ICA-GARCH) to overcome those flaws. This new model is applied to predict the return volatility of securities market and to improve the forecasting effect of return rate eventually. The empirical studies of the return volatility of Alibaba concept stocks show that the PSO-ICA-GARCH mode is of higher separation accuracy and more accurate model prediction effect than O-GARCH and ICA-GARCH models.

Key words: stock market volatility; ICA; PSO; GARCH model

对单个资产的收益波动率和多个资产之间的条件协方差矩阵(通常也称为多元波动率)的研究^[1-4]是当前金融计量学领域的重要内容。主要的多元波动率模型有 BEKK 模型^[5]、常值条件相关系数(CCC-GARCH)模型^[6]、动态条件相关系数(DCC-GARCH)^[7]模型等。在资产组合维数较高的情况

下, 上述多元波动率模型均存在待估参数数量巨大的问题。为了解决增加变量引起维数灾难的问题, 在多元波动率模型中引入了一系列降维思想。Alexander^[8]将主成分分析引入了多元波动率建模, 提出了 O-GARCH 模型, 该模型通过主成分分解将一组变量的条件协方差矩阵的问题转化成了分别考虑

收稿日期: 2020-08-29; 网络出版日期: 2021-04-19

网络出版地址: <https://kns.cnki.net/kcms/detail/61.1294.n.20210416.1533.002.html>

基金项目: 国家自然科学基金资助项目(61976176)

第一作者: 周晓玲, 女, 硕士生, 研究方向为金融数学。E-mail: 1121620683@qq.com

通信作者: 王小侠, 女, 博士, 副教授, 研究方向为量化投资。E-mail: wangxiaoxia@xaut.edu.cn

它们主成分的一元波动率的问题。但 O-GARCH 模型中采用的假设“主成分之间的条件协方差矩阵是对角阵”通常是不成立的,因为主成分之间的无条件不相关并不意味着条件不相关。2005 年 Wu 等^[9]将独立分量分析(independent component analysis, ICA)引入多元波动率建模,对纽约和香港股票市场进行实证分析时,将残差序列用 ICA 进行分解,然后对得到的独立成分分别建立 GARCH 模型。结果表明该方法对多只股票的收益率波动的估计方面比用 PCA 方法分解残差更有效,该模型为资产组合的选择和风险管理提供了新思路,且这种方法是基于独立分量的单变量 GARCH 模型,故计算成本很低。2012 年 García-Ferrer 等^[10]提出了一个新的条件异方差因素模型 GICA-GARCH 模型,该模型结合了 ICA 和多元 GARCH(MGARCH)模型。GICA-GARCH 模型使用单变量 ARMA-GARCH 模型将独立成分的估计与其拟合分开。并且通过马德里股票市场的经验应用评估得出 GICA-GARCH 比 CUC-GARCH 和 O-GARCH 模型有更强的一步波动率预测能力。2018 年刘鑫^[11]研究了基于 ICA 的多元波动率模型,探讨了 ICA 在证券市场的收益率序列波动率建模中应用的可行性及模型的拟合与估计效果的优势。2018 年 Lin^[12]利用 GARCH 类型模型研究上证综合指数的计量经济学特征,比较发现 EGARCH(1,1)(非对称)的拟合和预测性能总体上优于 GARCH(1,1)(对称)和 TAR(1,1)模型。

但 ICA 多采用梯度算法对目标函数进行优化来确定最优解,梯度算法具有收敛精度低、可能陷入局部最小点等缺点。而粒子群算法(particle swarm optimization, PSO)因其建模简单、适用性广、全局寻优能力强等优点可用来解决以上问题。在构造投资组合或进行资产配置的时候,协方差矩阵是构造有效边界的主要参数,故提出了各类不同的关于波动率的动态计量模型^[13]和预测方法。

1 PSO-ICA 算法

1.1 算法构造及步骤

传统的 ICA 是指从线性混合的数个统计独立的源信号的混合信号中分离出源信号的一种技术。观测信号 $x(t)$ 是多个独立信源 $s(t)$ 经混合矩阵 A 组合而成。ICA 的任务是在 $s(t)$ 与 A 均未知的条件下,求解一个解混矩阵 W ,使得 $x(t)$ 通过它后的输出 $y(t)$ 是 $s(t)$ 的最佳逼近。该算法确定解混矩阵的过程可以看作是对某一独立性判据进行寻优,

使各分量之间达到相互独立的过程,等价于 PSO 算法的目标函数和优化算法,因此可以将 PSO 算法引入 ICA 算法中,将负熵

$$J(y) \propto [E\{G(y)\} - E\{G(v)\}] \quad (1)$$

最大化作为目标函数,其中 v 是与 y 具有相同方差的零均值 Gauss 变量, E 为均值运算, G 为非线性函数。利用 PSO 算法粒子全局寻优的方法替代 ICA 的梯度算法,将满足目标函数和最大迭代次数得到的全局最优位置向量作为解混矩阵 W 的一行,依次更新循环得到解混矩阵 W 。

PSO-ICA 算法步骤为如下。

Step1. 对观测信号 X' 中心化得到均值为 0 的信号 X :

$$X = X' - E(X') \quad (2)$$

白化信号 X 使其具有单位方差且不相关:

$$Z = D^{-1/2} P^T X \quad (3)$$

其中 D 和 P 分别是 X 的协方差矩阵的特征值矩阵和特征向量矩阵。

Step2. 设定初始随机解混矩阵 $W = [W_1, W_2, \dots, W_m]^T$ 。

Step3. 当 $p = 1$ 时,以初始随机解混矩阵 W 的行数 m 和列数 d 分别作为 PSO 算法中粒子的个数和维数,以 $W_i = [w_{i1}, w_{i2}, \dots, w_{id}]$ 作为粒子的位置向量,随机初始化每个粒子的速度 $V_i = [v_{i1}, v_{i2}, \dots, v_{id}]$,其中 $i = 1, \dots, m$ 。

Step4. 给出最大迭代次数 T 及评价的适应度函数为:

$$\text{fitness}(Y_i) = E\{-\exp(-Y_i^2/2)\} \quad (4)$$

其中 $Y_i = W_i Z$, 存储每个粒子的最大适应度值和位置 p_i , 并从群体中选取最大的适应度值及其位置 p_g 。

Step5. 进行每一代粒子速度和位置的更新:

$$\begin{cases} V_i(t+1) = V_i(t) + c_1 \text{rand}_1(p_i(t) - W_i(t)) + \\ \quad c_2 \text{rand}_2(p_g(t) - W_i(t)) \\ W_i(t+1) = W_i(t) + V_i(t+1) \end{cases} \quad (5)$$

式中: c_1 和 c_2 为学习因子,本文均取 2; rand_1 和 rand_2 为 $[0,1]$ 内的随机数。

Step6. 判断是否达到预定的迭代次数,如果没有达到,返回 Step 4; 如果达到,停止迭代,输出最优的位置向量 W_p 。

Step7. 对解混矩阵 W 进行正交和归一化处理,避免分离同一信号以及保证分离的稳定性。

Step8. 判断 W 是否所有行向量完成运算。令 $p = p + 1$, 若 $p \leq m$, 返回 Step 3; 反之,停止循

环,确定分离矩阵 W 。

Step9. 输出分离信号 $Y = WZ$ 。

1.2 实验分析

实验中分别选取信号点数为 200 的正弦信号

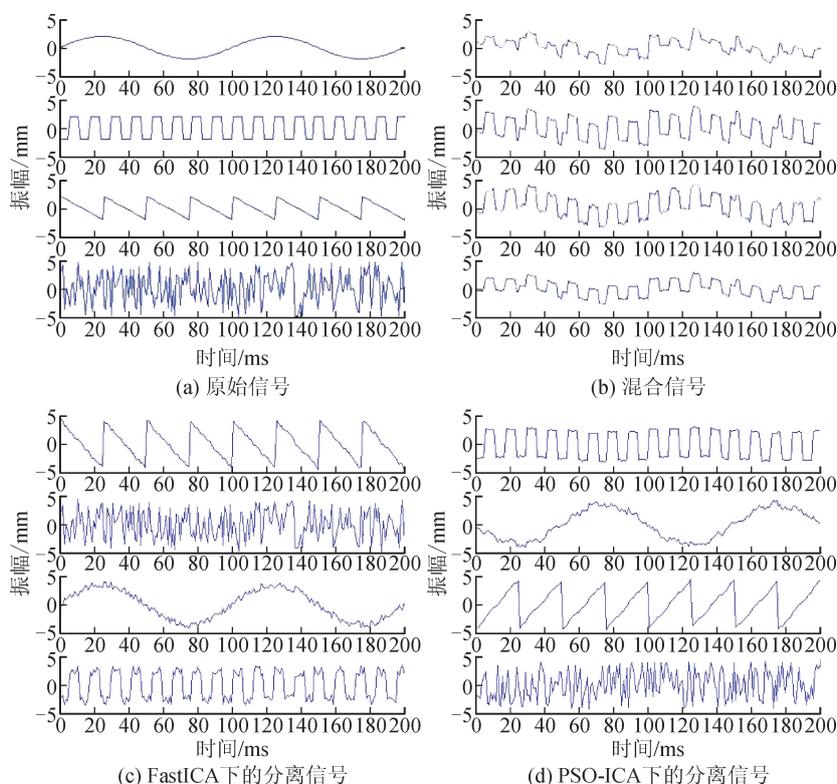


图 1 FastICA 和 PSO-ICA 实验结果图

Fig. 1 Experimental results of FastICA and PSO-ICA

表 1 FastICA 和 PSO-ICA 算法的信噪比
Tab. 1 SNR of FastICA and PSO-ICA algorithms

信噪比	算法类型	
	FastICA	PSO-ICA
s_1	13.757 9	13.447 9
s_2	9.156 9	12.936 0
s_3	14.781 6	14.607 9
s_4	5.581 4	6.678 9

表 2 原始信号与分离信号的相关系数
Tab. 2 Correlation coefficient of original signal and separated signal

原始信号	s_1	s_2	s_3	s_4
FastICA 分离信号 y_3	0.988 7	0.028 5	0.011 1	0.012 8
y_4	0	0.977 6	0.022 6	0.011 4
y_1	0	0.001 7	0.997 0	0.012 6
y_2	0.037 9	0.039 3	0.031 8	0.937 9
PSO-ICA 分离信号 y_1	0.986 9	0.104 0	0.055 6	0.011 6
y_3	0.104 6	0.993 2	0.066 9	0.002 3
y_4	0.063 1	0.020 9	0.996 2	0.002 1
y_2	0.031 8	0.001 6	0.003 4	0.949 6

s_1 、方波信号 s_2 、锯齿形信号 s_3 、随机信号 s_4 作为检测信号,检验 PSO-ICA 算法的有效性。图 1 是 FastICA 算法和 PSO-ICA 算法的分离结果。表 1 是分离结果的信噪比,表 2 是两种方法分离结果的相关系数。

由图 1 可以看出,与 FastICA 相比 PSO-ICA 具有较好的分离效果,尤其在方波形信号中效果更加明显。需要指出的是分离结果显示分离信号顺序与原始信号顺序出现不同,并且某些信号与原始信号反相,这是由 ICA 算法所固有的分离信号的排列次序和波形的幅度与相位的不确定性引起的,并不影响信号的提取。

在同一混合矩阵下,分离信号与原始信号的信噪比参数越大表明分离的效果越好。由表 1 可以看出, s_1 和 s_3 相近,但 PSO-ICA 算法的 s_2 和 s_4 均远大于 FastICA 算法的信噪比,说明 PSO-ICA 分离结果的信噪比更高。

由表 2 可以看出,两种方法关于正弦信号和锯齿信号的相关系数相近,但对方波信号和随机信号,PSO-ICA 算法对应的相关系数明显大于 ICA 算法的相关系数,更接近于 1,说明 PSO-ICA 算法具有更高的分离精度,分离效果更好。

综合图 1、表 1 和表 2,不难看出,无论从视觉直观还是数据客观角度,都显示出 PSO-ICA 比 FastICA

有更好的分离效果,因此在接下来的工作中我们选择 PSO-ICA 算法进行股票收益的多元波动率建模。

2 PSO-ICA-GARCH 模型

2.1 模型原理

对股票收益进行多元波动率建模时, O-GARCH模型假设各主成分之间弱相关,在实证分析时,往往会产生预测效果和实际情况不相符的问题。

ICA-GARCH 模型中 ICA 算法存在收敛精度低及容易陷入局部最优的问题。本文将 PSO-ICA 算法与 GARCH 模型结合构造 PSO-ICA-GARCH 模型,可以有效克服如上问题。

PSO-ICA-GARCH 模型首先通过 PSO-ICA 算法将股票收益率序列 r_t 分解为相互独立的成分 s_t , 即如果存在矩阵 A 以及 d 维向量 $s_t = (s_{1t}, s_{2t}, \dots, s_{dt})$, 其中对每个时刻 t , s_{it} 和 s_{jt} ($i \neq j$) 都是相互独立的,使得(1)成立,则称 s_t 是 r_t 的 d 个独立成分,此时条件协方差矩阵 V_t 是一个对角阵,且 PSO-ICA 算法假设独立成分是服从非 Gauss 分布的,这更符合金融时间收益率序列数据的特性,然后对每个独立成分 s_{it} 进行单元 GARCH 建模,最后表出收益率序列 r_t 的条件协方差矩阵 H_t 。

PSO-ICA-GARCH(1,1)模型如下:

$$r_t = As_t \quad (6)$$

$$s_{it} = v_{it}\alpha_{it}, \alpha_{it} \sim i.i.d(0,1) \quad (7)$$

$$v_{it}^2 = \omega + \alpha s_{i,t-1}^2 + \beta v_{i,t-1}^2 \quad (8)$$

式中: A 为混合矩阵; $\{s_{it}\}$ 为独立成分; v_{it} 为独立成分 $\{s_{it}\}$ 的方差; V_t 是由 v_{it} 组成的对角矩阵。则收益率序列 r_t 的条件协方差矩阵为 $H_t = AV_tA^T$ 。

式(6)将收益率序列由 PSO-ICA 算法转换为独立成分,式(7)~(8)是对独立成分的一元 GARCH 模型估计。

2.2 模型算法步骤

Step1. 对各股收盘价格进行取对数差分处理后得到对应的收益率序列。

Step2. 作各股收益率序列图,观察其是否表现出尖峰厚尾和聚集性等特征。

Step3. 对各股收益率序列的相关统计特征进行分析,如峰度、偏度、正态分布检验(J-B 检验)和平稳性验(ADF 检验)。

Step4. 判断各收益率序列是否具有自相关性,若有采用 AR 模型去除其自相关性。

Step5. 判断各股残差序列是否具有 ARCH

效应。

Step6. 剔除掉没 ARCH 效应的收益率序列,对满足条件的对数收益率序列采用 PSO-ICA 算法,对得到的独立成分分别进行单元 GARCH 模型拟合和预测。

Step7. 对 PSO-ICA-GARCH 模型进行拟合和预测效果检验。

3 实证分析

3.1 数据选取

概念股作为一类共同特征股票的总称它们收益率的波动往往受市场同一因素的影响,其价格波动也存在着一定的共性,故本文随机选取 5 支阿里巴巴概念股进行实证研究。分别是万隆光电、海尔智家、视觉中国、分众传媒和华胜天成股票,从 2018 年 1 月 2 日到 2019 年 12 月 31 日为期 487 天收盘价交易数据,对各股收盘价格进行取对数差分处理后得到对应的对数收益率序列:

$$r_{i,t} = \ln p_{i,t} - \ln p_{i,t-1} \quad (9)$$

式中: $p_{i,t}$ 为第 i 只股票 t 时刻的收盘价格; $r_{i,t}$ 表示第 i 只股票 t 时刻的对数收益率,并做百分比处理。

3.2 数据的统计性质

表 3 给出了五支股票收益率数据的统计性质。可以看出,海尔智家的收益率均值为正值,说明这支股票当期收益处于盈利状态,其它四支股票的收益率均值都为负值,说明当期股票处于亏损状态。

标准差代表各支股票收益率的风险大小,海尔智家当期盈利较多且相应的风险最小,分众传媒当期亏损最大,但风险相对较小,万隆光电当期亏损最小,但是风险最大。

其中各股对数收益率序列的偏度不为 0,海尔智家、视觉中国和分众传媒对数收益率序列的偏度都大于 0 为右偏,剩余两支股票的对数收益率序列表现出一定程度的左偏。

各股对数收益率序列的超额峰度均大于 0,表现一定程度的厚尾性,其中海尔智家对数收益率序列的厚尾性最为明显,且 J-B 统计量对应 p 值接近于 0,故拒绝收益率序列为正态分布的原假设,即各股对数收益率数据都表现出尖峰厚尾的背离正态分布的性质。

ADF 检验对应的 p 值均小于显著性水平 0.01,故拒绝各支股票的对数收益率有单位根(非平稳序列)的原假设,故这 5 支股票的对数收益率序列皆是平稳序列,可以直接进行模型估计。

表 3 对数收益率序列统计性质
Tab.3 Statistical properties of logarithmic return series

指数	股票名称				
	万隆光电	海尔智家	视觉中国	分众传媒	华胜天成
收益率均值	-0.082 556	0.005 453	-0.025 768	-0.166 785	-0.004 540
收益率标准差	3.441 440	2.199 613	3.261 495	2.778 630	3.364 276
收益率最大值	9.537 658	8.157 999	9.527 339	9.494 428	9.568 269
收益率最小值	-10.551 190	-9.612 518	-10.548 343	-12.553 187	-10.599 024
收益率偏度	-0.202 838	0.189 259	0.036 368	0.170 463	-0.035 309
超额峰度	1.617 462	1.738 905	1.212 176	1.655 217	1.251 887
J-B 检验 P 值	1.000 0e-03(****)				
ADF 检验 P 值	1.000 0e-03(****)				

3.3 自相关性检验

自相关就是随机扰动项的各个值之间存在着相关关系。自相关性会致使模型的参数估计发生偏差,得不到有效无偏的最优估计。对选取的五支股票的对数收益率序列进行自相关检验,结果显示各支股票的日收益率序列在高阶滞后阶时恰好均无自相关性。

需要说明的是:若收益率序列具有自相关性,需用 AR 模型去除其自相关性。

3.4 ARCH 效应检验

记 $a_t = r_t - \mu_t$, 可以通过收益率残差平方序列 a_t^2 的自相关性检验来验证各每支股票的异方差性,即 ARCH 效应。各股收益率残差平方序列的自相关检验结果见图 2。

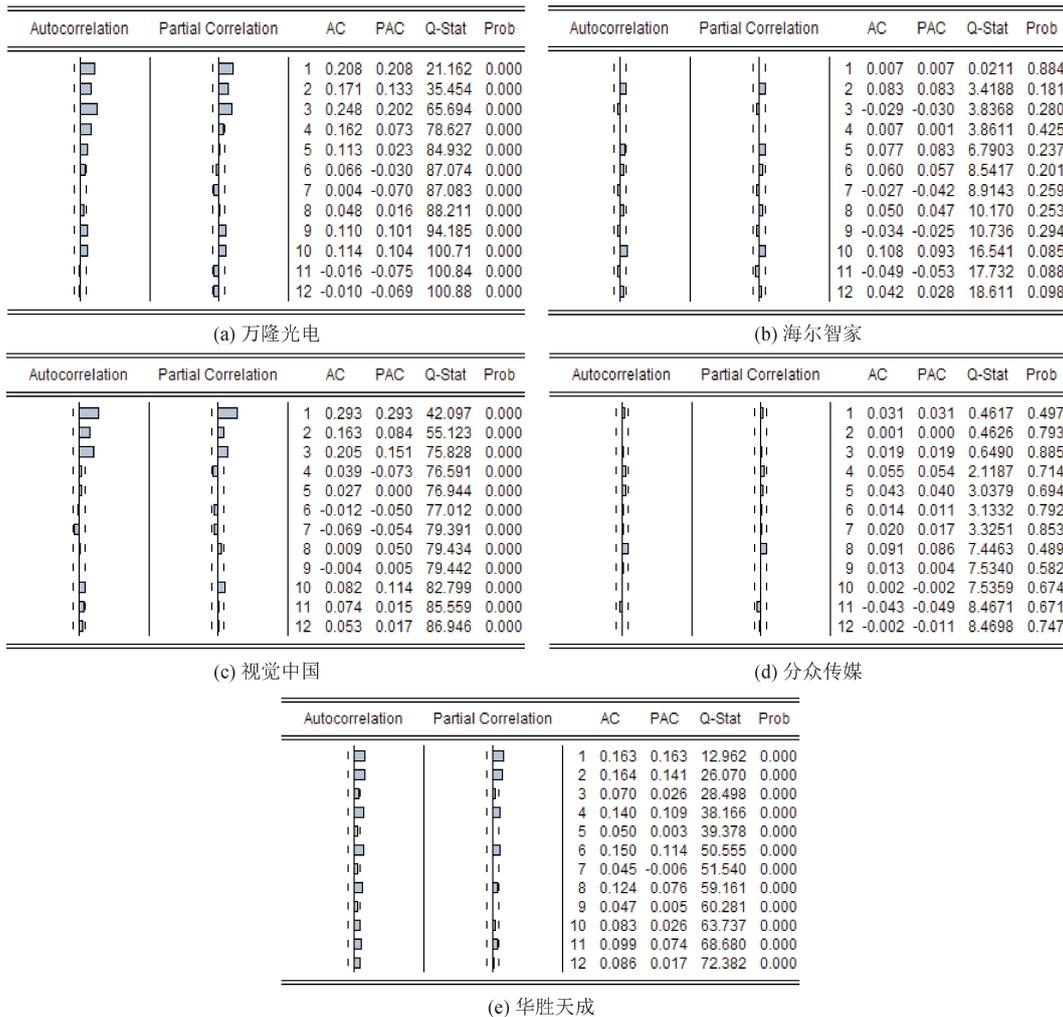


图 2 各股收益率残差平方序列的自相关检验图
Fig.2 Autocorrelation test chart of the square series of the return of each stock

从图 2 可以看出,海尔智家和分众传媒的对数收益率残差平方序列在各滞后阶下,均在 0.05 的显著性水平下接受原假设,即收益率残差平方序列不具有自相关性,也即不具有 ARCH 效应;万隆光电、视觉中国和华胜天成的对数收益率残差平方序列在各滞后阶下存在自相关性,则这三支股票具有很强的 ARCH 效应,可以进行 GARCH 建模。

3.5 模型参数估计与模型检验

由表 3 可知,所选取的这三支阿里巴巴概念股的对数收益率数据均不服从正态分布,因此在对收益率序列进行 O-GARCH、ICA-GARCH 和 PSO-ICA-GARCH 建模时,采用 t 分布可以更好地刻画序列的特性。用 PCA、ICA 和 PSO-ICA 算法对三组收益率序列提取主成分和独立成分,然后分别对三组主成分和独立成分进行 GARCH(1,1)模型拟合,结果见表 4,表 5 和表 6,其中***, **, * 分别表示在显著性水平 1%、5%和 10%下显著。

表 4 O-GARCH(1,1)模型的参数估计

Tab. 4 Parameter estimation of O-GARCH (1,1) model

PC	O-GARCH (1,1)模型参数		
	ω	α	β
PC_1	1.072 20	0.075 15 (**)	0.876 16 (***)
PC_2	2.095 25 (***)	0.375 11 (***)	0.394 47 (***)
PC_3	0.101 52	0.098 24 (**)	0.892 20 (***)

表 5 ICA-GARCH(1,1)模型的参数估计

Tab. 5 Parameter estimation of ICA-GARCH (1,1) model

IC	ICA-GARCH(1,1)模型参数		
	ω	α	β
IC_1	0.074 31 (*)	0.102 66 (***)	0.829 85 (***)
IC_2	0.274 92 (**)	0.245 03 (***)	0.479 82 (***)
IC_3	0.124 86	0.250 10	0.653 88 (*)

表 6 PSO-ICA-GARCH(1,1)模型的参数估计

Tab. 6 Parameter estimation of PSO-ICA-GARCH (1,1) model

IC	PSO-ICA-GARCH(1,1)模型参数		
	ω	α	β
IC_1	0.056 04	0.078 15 (**)	0.870 67 (***)
IC_2	0.278 96 (***)	0.371 90 (***)	0.394 88 (***)
IC_3	0.016 32	0.102 09 (**)	0.888 79 (***)

用模型 O-GARCH、ICA-GARCH 和 PSO-ICA-GARCH 对收益率序列进行主成分和独立成分提取时,转换矩阵分别为 W_1 、 W_2 和 W_3 :

$$W_1 = \begin{bmatrix} 0.6198 & -0.5177 & -0.5899 \\ 0.5004 & 0.8397 & -0.2111 \\ 0.6045 & -0.1644 & 0.7794 \end{bmatrix} \quad (10)$$

$$W_2 = \begin{bmatrix} -0.1313 & 0.7597 & 0.6369 \\ 0.2338 & -0.6006 & 0.7646 \\ 0.9634 & 0.2493 & -0.0988 \end{bmatrix} \quad (11)$$

$$W_3 = \begin{bmatrix} -0.0051 & 0.0230 & 0.9997 \\ -0.0150 & 0.9996 & -0.0231 \\ 0.9999 & 0.0151 & 0.0048 \end{bmatrix} \quad (12)$$

将参数估计结果代入 PSO-ICA-GARCH(1,1)多元波动率模型,即可得到股票收益率协方差矩阵 H_t 。为了检验模型的有效性,我们对回归模型的残差进行了检验。记残差向量 $\hat{\epsilon}_t = H_t^{-1/2} r_t$ [14],对每一个 i ,原假设为残差序列的历史值与预测值线性无关, F 检验结果见表 7。

表 7 O-GARCH、ICA-GARCH 和 PSO-ICA-GARCH 模型检验结果比较

Tab. 7 Comparison of test results of O-GARCH、ICA-GARCH and PSO-ICA-GARCH models

F	模型类型		
	O-GARCH	ICA-GARCH	PSO-ICA-GARCH
F_1	28.655 (***)	19.024 (***)	29.836 (***)
F_2	16.986 (***)	25.518 (***)	13.410 (**)
F_3	10.049 (*)	5.670	8.554

注: F_i 表示的是对第 i 个残差序列作检验的 F 统计量,其中滞后阶选为 5。

由表 7 可以看出,三种模型的 F_1 统计量在 0.01 的显著性水平下均显著,三种模型拟合效果较一致。 F_3 统计量中只有 O-GARCH 模型在 0.1 的显著性水平下显著,其它两种模型均不显著,说明 ICA-GARCH 模型和 PSO-ICA-GARCH 模型的拟合效果均优于 O-GARCH 模型。 F_2 统计量中 PSO-ICA-GARCH 模型在 t 分布下是在 0.05 的显著性水平下显著,且 PSO-ICA-GARCH 模型中统计量的值明显小于其它两个模型,说明 PSO-ICA-GARCH 模型的拟合效果明显优于其它两种模型。综上所述,PSO-ICA-GARCH 模型相较于 O-GARCH 和 ICA-GARCH 模型,具有更好的模型拟合效果。

3.6 模型预测效果比较

参照 Pelletier^[15] 的做法,用自适应平均绝对偏差(adaptive mean absolute deviation,AMAD)检验预测效果,其定义为:

$$AMAD(p) = \frac{1}{d^2} \sum_{i,j=1}^d E | h_{ij,t+p|t} - \frac{1}{2m+1} \sum_{k=-m}^m r_{i,t+p+k} r_{j,t+p+k} | \quad (13)$$

式中 m 的作用是对随机的误差进行平均处理。

当 $m=0$ 时,三种模型向后 5 步预测的 AMAD 值和预测效果分别见表 8 和图 3。

表 8 O-GARCH,ICA-GARCH 和 PSO-ICA-GARCH 模型的预测效果

Tab.8 Prediction results of O-GARCH, ICA-GARCH and PSO-ICA-GARCH models

m	p	O-GARCH	ICA-GARCH	PSO-ICA-GARCH
	1	0.280 3	0.225 2	0.218 2
	2	1.000 8	0.905 6	0.900 5
0	3	0.982 2	1.059 0	1.062 7
	4	0.255 7	0.090 0	0.096 2
	5	0.645 2	0.572 6	0.565 0

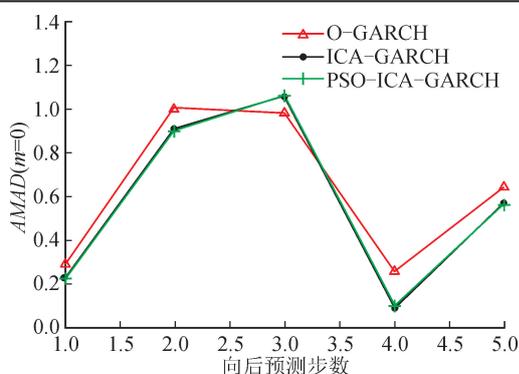


图 3 O-GARCH,ICA-GARCH 和 PSO-ICA-GARCH 模型在 t 分布下的预测效果

Fig.3 Prediction effect of O-GARCH, ICA-GARCH and PSO-ICA-GARCH models under t distributions

从图 3 容易看出,ICA-GARCH 和 PSO-ICA-GARCH 模型整体上明显比 O-GARCH 模型的预测偏差小,说明 ICA-GARCH 和 PSO-ICA-GARCH 模型整体上明显比 O-GARCH 模型的预测更准确。更进一步,从表 8 可以看出,除向后第 3、4 步 PSO-ICA-GARCH 和 ICA-GARCH 模型的预测结果相当外,向后第 1、2 和 5 步 PSO-ICA-GARCH 的预测偏差均明显小于 ICA-GARCH 模型。综合图 3 和表 8 的分析结果,说明三种模型中,PSO-ICA-GARCH 模型预测的效果最准确。

4 结 论

本文将 PSO-ICA 算法与 GARCH 模型相结合,提出了一种新的多元波动率模型,即 PSO-ICA-GARCH 模型,该模型能够和 ICA-GARCH 模型同样解决 O-GARCH 模型中各主成分之间弱相关,使得所做实证往往与实际情况不相符的问题,且 PSO-ICA 算法相较于 ICA 算法具有更高的分离精度,并将该模型应用到阿里巴巴概念股收益的多元波动率建模中,结果表明 PSO-ICA-GARCH 模型相较于 O-GARCH 和 ICA-GARCH 模型具有更好的模型预测效果,为实现更精确的多元波动率建模提供了有力的工具。

参考文献:

- [1] TSAY R S. Analysis of financial time series[M]. New York: John Wiley & Sons, 2001.
- [2] 朱涛,卢建,江孝感. MGARCH 模型对金融时间序列刻画能力的研究[J]. 数理统计与管理,2014,33(5): 860-868.
ZHU Tao, LU Jian, JIANG Xiaogan. Research on the ability of MGARCH to describe financial time series [J]. Journal of Applied Statistics and Management, 2014, 33(5): 860-868.
- [3] ISERINGHAUSEN M. The time-varying asymmetry of exchange rate returns: a stochastic volatility-stochastic skewness model [J]. Journal of Empirical Finance, 2020, 58:275-292.
- [4] BOLLERSLEV T, PATTON A J, QUAEDEVLIET R. Multivariate leverage effects and realized semicovariance GARCH models[J]. Journal of Econometrics,2020,217(2): 411-430.
- [5] LIEN D, TSE Y K, TSUI A K C. Evaluating the hedging performance of the constant-correlation GARCH model [J]. Applied Financial Economics, 2002, 12(11):791-798.
- [6] BOLLERSLEV T. Modelling the coherence in short-run

- nominal exchange rates: a multivariate generalized ARCH model [J]. *Review of Economics & Statistics*, 1990, 72(3):498-505.
- [7] ENGLE R F, KRONER K F. Multivariate simultaneous generalized ARCH [J]. *Econometric Theory*, 1995, 11(1):122-150.
- [8] ALEXANDER C. A primer on the orthogonal GARCH model[J]. *Manuscript Isma Centre*, 2000, 13(3):187-192.
- [9] WU E H C, YU P L H, LI W K. Value at risk estimation using independent component analysis generalized autoregressive conditional heteroscedasticity (ICA-GARCH) models[J]. *International Journal of Neural Systems*, 2008, 16(5):371-382.
- [10] GARCÍA-FERRER A, GONZÁLEZ-PRIETO E, PEÑA D. A conditionally heteroskedastic independent factor model with an application to financial stock returns[J]. *International Journal of Forecasting*, 2012, 28(1):70-93.
- [11] 刘鑫. 基于独立成分分析的证券市场波动性分析[D]. 西安:西安电子科技大学, 2018.
- LIU Xin. Analysis of volatility analysis of stock market based on independent composition analysis [D]. Xi'an: Xi'an University of Electronic Science and Technology, 2018.
- [12] LIN Zhe. Modelling and forecasting the stock market volatility of SSE Composite Index using GARCH models[J]. *Future Generation Computer Systems*, 2018, 79(3):960-972.
- [13] WANG Xiaoxia, XING Jianhong. Time fractional CGMY model for the numerical pricing of European call options[J]. *Journal of Physics: Conference Series*, 2020, 1592:012047.
- [14] 王明进, 陈奇志. 基于独立成分分解的多元波动率模型[J]. *管理科学学报*, 2006, 9(5):56-64.
- WANG Mingjin, CHEN Qizhi. Multivariate volatilities modeling based on independent components[J]. *Journal of Management Sciences in China*, 2006, 9(5):56-64.
- [15] PELLETIER D. Regime switching for dynamic correlations[J]. *Journal of Econometrics*, 2006, 131(1/2):445-473.

(责任编辑 王绪迪)

(上接第579页)

- [13] 丁魁礼, 钟书华. 创新集群中知识、组织和制度的共生演化[J]. *科学学研究*, 2013, 31(12):1899-1906.
- DING Kuili, ZHONG Shuhua. The co-evolution of knowledge, organization and institution of innovation clusters[J]. *Research in Science of Science*, 2013, 31(12):1899-1906.
- [14] ZENG Fue, SHI Shengping, LI Ji, et al. Strategic symbiotic alliances and market orientation: an empirical testing in the Chinese car industry[J]. *Asia Pacific Business Review*, 2013, 19(1):53-69.
- [15] STRAUSS A. *Qualitative analysis for social scientists* [M]. Cambridge: Cambridge University, 1987.
- [16] 温兴琦, 黄起海, BROWN D. 共生创新系统: 结构层次、运行机理与政策启示[J]. *科学学与科学技术管理*, 2016, 37(3):79-85.
- WEN Xingqi, HUANG Qihai, BROWN D. Study on layers, operating mechanisms and policy implications of co-existing innovation system[J]. *Science of Science and Management of S. & T.*, 2016, 37(3):79-85.
- [17] 李明敏, 李秉祥, 惠祥. 混合所有制企业资源异质股东共生关系形成机理——以中国联通混改方案为例[J]. *经济学家*, 2019(6):70-79.
- LI Mingmin, LI Bingxiang, HUI Xiang. The formation mechanism of symbiotic relationship among resources heterogeneous shareholders in mixed ownership enterprises-taking China Unicom's mixed-reform plan as an example[J]. *Economist*, 2019(6):70-79.
- [18] 赵坤, 郭东强, 刘闲月. 众创式创新网络的共生演化机理研究[J]. *中国软科学*, 2017(8):74-81.
- ZHAO Kun, GUO Dongqiang, LIU Xianyue. A study on the symbiosis evolution mechanism of enterprise's crowd innovation network [J]. *China Soft Science*, 2017(8):74-81.

(责任编辑 王绪迪)