

DOI: 10.13718/j.cnki.xdzk.2021.11.017

基于已实现极差的上证综指波动长记忆性 识别与风险度量研究

周文浩, 王沁, 张红梅, 汪玲

西南交通大学 数学学院统计系, 成都 611756

摘要: 基于上证综指的高频信息, 计算了已实现极差. 针对已实现极差, 进行 R/S 检验和单位根检验, 发现已实现极差具有长记忆性. 考虑到杠杆效应、异方差性和长记忆性, 构建了基于已实现极差的 ARFIMA-M-FIGARCH 模型、ARFIMA-M-FIEGARCH 模型和 ARFIMA-M-HYGARCH 模型, 进行了拟合优度检验、 VaR 的失败率检验以及 VaR 的动态分位数检验, 结果表明, 基于已实现极差的 ARFIMA-M-HYGARCH 模型拟合效果最优, 刻画了上证综指的双长记忆特征、杠杆效应和尖峰厚尾的特征, 能更好地度量极端情况下的在险价值 VaR .

关键词: 已实现极差; 双长记忆; R/S 检验; ARFIMA-M-HYGARCH 模型; 在险价值

中图分类号: F830.91

文献标志码: A

开放科学(资源服务)标识码(OSID):



文章编号: 1673-9868(2021)11-0142-09

RRV-Based Research of Identifying Long Memory Property and Risk Measurement for Shanghai Composite Index Volatility

ZHOU Wenhao, WANG Qin, ZHANG Hongmei, WANG Ling

College of Mathematics and Statistics, Southwest Jiaotong University, Chengdu 611756, China

Abstract: Realized range variance (RRV) is computed with the high-frequency data sampling from Shanghai Composite Index. R/S test and unit root test are carried out to prove its long memory property. Considering leverage effect, heteroscedasticity and long memory property, RRV-based ARFIMA-M-FIGARCH, ARFIMA-M-FIEGARCH and ARFIMA-M-HYGARCH models are established. Goodness-of-fit test, failure rate test and dynamic quantile test are used to evaluate the models. Results show that ARFIMA-M-HYGARCH, which reflects dual long memory property, leverage effect and “peak fat tail” property of Shanghai Composite Index, is better fitted and measures VaR (value at risk) more precisely in extreme cases.

Key words: realized range variance; dual long memory; R/S test; ARFIMA-M-HYGARCH; value at risk

收稿日期: 2019-12-29

基金项目: 国家自然科学基金项目(71671145); 教育部人文社会科学研究基金项目(17YJC790119).

作者简介: 周文浩, 硕士研究生, 主要从事金融风险管理研究.

通信作者: 王沁, 副教授.

在全球经济一体化的推进下, 中国金融市场的波动日益加剧, 金融风险也随之不断增加, 因此, 对金融市场风险进行度量与控制是非常有必要的. VaR 作为金融风险度量的关键指标, 将不同资产的组合风险综合成一个数值进行度量, 在国际金融市场得到了广泛认可与应用.

资产收益波动的估计是度量 VaR 的关键, 为此国内外学者通常选用 GARCH 簇模型来对资产波动进行度量, 进而实现对 VaR 更有效地控制与预测. 文献 [1] 结合 EVT 与 GARCH 模型对市场的 VaR 进行预测, 实现了极端风险的精确度量; 文献 [2] 基于 GARCH 模型, 针对基金收益率序列, 计算各种基金收益率序列的 VaR , 发现各基金具有相似的风险偏好; 文献 [3] 利用对冲基金日交易数据, 建立了 GARCH 模型, 预测对冲基金的波动率并计算其 VaR , 减少对冲基金激进的投资策略对市场的冲击; 文献 [4] 用 ARFIMA-ARCH 模型来对中国股票市场长记忆性进行分析并对 VaR 进行测算与检验; 文献 [5] 基于 ARFIMA-GARCH-F 模型对重庆市空气质量指数 (AQI) 的 VaR 进行了度量与检验; 文献 [6] 基于不同分布下的 FIGARCH 计算了期货的 VaR , 结果表明 FIGARCH 相较于 GARCH 模型更精确; 文献 [7] 结合有偏 t 分布与 FIGARCH 对股票市场的 VaR 进行测算与检验, 证明了 FIGARCH 在实践中风险控制的优越性; 文献 [8] 应用 ARFIMA-FIGARCH 模型对同业拆借利率进行度量并结合 VaR 对模型优劣进行检验, 结果表明 ARFIMA-FIGARCH 能更好地刻画同业拆借利率的波动特征. 尽管双长记忆的 ARFIMA-FIGARCH 模型能有效地刻画资产收益的双长记忆性和异方差性, 但考虑杠杆效应的存在以及高阶矩对收益的影响, 需要对 ARFIMA-FIGARCH 模型进行修正与拓展, 从而有效地度量股票市场的 VaR 以及预测和检验.

考虑到高频数据日内“U”型特点, 文献 [9] 结合高频信息首次提出“已实现”波动率 (realized volatility, RV), 作为波动率的全新非参数度量方法; 文献 [10] 建立 ARFIMA-RV 模型并实证表明 RV 的引入能很好地刻画资产的波动特征并大幅度提升模型的拟合与预测能力; 文献 [11] 基于已实现波动率建立了 ARFIMAX-FIGARCH 模型, 对农产品期货市场波动率进行预测, 结果表明引入 RV 能使 ARFIMA-FIGARCH 模型预测精度更高. 但真实市场往往可能存在跳跃点, 这导致 RV 的稳健性与有效性可能难以成立. 因此文献 [12] 结合高频极差信息提出了已实现极差 (realized range variance, RRV), 并证明 RRV 的有效性约为 RV 的 5 倍, 实现了对 RV 与市场真实波动率拟合的优化. 文献 [13] 在理论上证明了已实现极差波动率是比已实现波动率更有效的波动估计量; 文献 [14] 基于已实现极差建立了 LHAR-RRV-CJ 模型, 分析了中国股市的异质性、跳跃性以及杠杆效应; 文献 [15] 基于已实现极差建立了 CARR-EVT 模型, 实现对日 VaR 和 $CVaR$ 的动态估计.

一方面, 由于对数化已实现极差具有双长记忆性和异方差性; 另一方面, 考虑到杠杆效应的存在以及高阶矩对收益的影响. 借鉴前述研究, 本文基于对数化已实现极差, 建立偏 t 分布下的 ARFIMA-M-FIGARCH 簇模型, 分析资产收益的双长记忆性以及异方差性, 分析杠杆效应下的极端风险, 以实现对上证综指 VaR 的度量与控制.

1 基于已实现极差的 ARFIMA-M-FIGARCH 簇模型

1.1 已实现极差

极差是某个日内间隔中最高价与最低价之差, 包含了时间间隔里的主要信息. 设 P_t 为第 t 日的收盘价, $P_{t,i}^{\max}$ 与 $P_{t,i}^{\min}$ 分别为第 t 日第 i 个日内最高价和日内最低价, N 为某个交易日 t 可获得的高频收益率数目, 则日收益率定义为: $r_t = \ln P_t - \ln P_{t-1}$. 参考文献 [12], 极差下的日内高频收益率定义为

$$r_{t,i} = \frac{(\ln P_{t,i}^{\max} - \ln P_{t,i}^{\min})}{\sqrt{4 \ln 2}}, \quad t = 1, \dots, T; \quad i = 1, \dots, N \quad (1)$$

则 RRV_t 定义为极差下的日内高频收益率的平方和:

$$RRV_t = \sum_{i=1}^N r_{t,i}^2 \quad (2)$$

1.2 双长记忆模型

文献[16]考虑到长记忆性, 提出了 FIGARCH(BBM) 模型, 并在 FIGARCH(BBM) 模型上对结构进行修正, 结合 ARFIMA 提出了 ARFIMA-FIGARCH(CHUNG) 模型, 其结构如下:

$$\begin{cases} \Phi(L)(1-L)^{d_1}(X_t - \mu) = \Theta(L)\varepsilon_t \\ \varepsilon_t = \sqrt{\sigma_t}e_t \\ (1-\beta(L))\sigma_t^2 = \omega + (1-\beta(L) - (1-\alpha(L) - \beta(L))(1-L)^{d_2})\varepsilon_t^2 \end{cases} \quad (3)$$

其中: $\Phi(L)$ 与 $\Theta(L)$ 分别为 p 阶自回归与 q 阶移动平均算子; $\alpha(L)$ 与 $\beta(L)$ 分别为方差方程的 ARCH 项和 GARCH 项; ε_t 为白噪声序列, 满足 $E(\varepsilon_t) = 0$, $E(\varepsilon_t^2) = \sigma^2 < \infty$, $E(\varepsilon_t\varepsilon_s) = 0$; d_1 与 d_2 分别为 X_t 序列与波动率的分数差分阶数, 当 $d_1, d_2 \in (-0.5, 0]$, 序列不具有长记忆性; 当 d_1 或 $d_2 \in (0, 0.5]$, 序列具有单长记忆性; 当 $d_1, d_2 \in (0, 0.5]$, 序列具有双长记忆性; $(1-L)^d$ 可视为分数阶差分, 常常用下式计算.

$$(1-L)^d = \sum_{k=0}^{\infty} \frac{\Gamma(k-d)}{\Gamma(k+1)\Gamma(-d)} L^k \quad (4)$$

考虑到杠杆效应, 文献[16]引入杠杆项 θ_1, θ_2 来对杠杆效应进行刻画, 进而构建了 FIEGARCH 模型, 其条件方差方程可以表示为:

$$(1-\alpha(L) - \beta(L))(1-L)^{d_2} \ln(\sigma_t^2) = \omega + \sum_{i=1}^q (\theta_1 \varepsilon_t + \theta_2 |\varepsilon_t|) \quad (5)$$

事实上收益序列的高阶矩未必存在, 这使得 FIEGARCH 的基本假设难以成立. 文献[17]引入 $\ln \alpha$ 创建了 HYGARCH 模型, 考虑了高阶矩对波动和长记忆性的影响, 其对应的条件方差可以表示为:

$$(1-\beta(L))\sigma_t^2 = \omega + (\alpha(L)\beta(L) - \beta(L)(1-\beta(L)))(1 + \ln \alpha(1-L)^{d_2})\varepsilon_t^2 \quad (6)$$

基于对数化已实现极差, 考虑到双长记忆性、异方差性、杠杆效应以及高阶矩对收益的影响, 本文构建了 ARFIMA-M-HYGARCH 模型:

$$\begin{cases} \Phi(L)(1-L)^{d_1}(\ln RRV_t - \mu - bz_{t-1} - c | z_{t-1} |) = \Theta(L)\varepsilon_t \\ \varepsilon_t = \sqrt{\sigma_t}e_t \\ (1-\beta(L))\sigma_t^2 = \omega + (\alpha(L)\beta(L) - \beta(L)(1-\beta(L)))(1 + \ln \alpha(1-L)^{d_2})\varepsilon_t^2 \end{cases} \quad (7)$$

由于 RRV 是非负的, 所以对 RRV 的对数建立模型, 从而分析极端情况下的风险价值. $z_t = \frac{r_t}{\sqrt{RRV_t}}$ 是标准化波动率, 杠杆效应通过 c 来表示, 如果 $c < 0$, 则表明负冲击对未来的影响大于正冲击.

2 VaR 的计算与检验

VaR 定义为在一定置信水平下, 资产组合在一段时间内可能受到的最大损失. 由此可以得出 VaR 的定义式:

$$P(\Delta P \leq VaR) = \alpha \quad (8)$$

针对对数化已实现极差的尖峰后尾特征, 选取偏 t 分布下 ARFIMA-M-HYGARCH 模型来建模, 可以得到 ARFIMA-M-FIGARCH 簇的 VaR 为:

$$VaR_t = u_t + skst_{\alpha} \sqrt{RRV_t} \quad (9)$$

其中: u_t 为 $\ln RRV$ 率的均值; $skst_{\alpha}$ 是标准偏 t 分布为 $skst(0, 1, \xi, \nu)$, 且下置信水平为 α 的单侧分位数, ξ 为偏度参数, ν 为自由度.

基于已实现极差的 ARFIMA-M-HYGARCH 模型计算与检验 VaR 的具体思路如下:

步骤一: 计算 RRV , 结合 R/S , 单位根检验以及自相关图识别其长记忆性, 利用 QQ 图判断其分布是否符合偏 t 分布.

步骤二: 基于分数阶差分后序列计算残差序列, 对残差序列进行异方差检验以及长记忆检验。

步骤三: 对基于已实现极差下的 ARFIMA-M-FIGARCH 簇模型进行参数估计以及拟合优度检验。

步骤四: 通过 $VaR_t = u_t + skst_\alpha \sqrt{RRV_t}$ 计算 VaR 在不同分位数下的值。

步骤五: 利用失败率检验法和动态分位数检验法对 VaR 进行检验。失败率检验法并未对分位数起到评估的作用且受样本量的影响较大, 而动态分位数检验法弥补了这一缺陷。

3 实证分析

3.1 数据收集

中国股票市场主要分为沪市和深市, 因此上证综指与深成指自然最能反映中国股市的整体波动情况, 但由于沪市与深市存在较高的相关性, 而沪市开市较早, 对外部冲击较为敏感, 同时对深市而言具有“溢出效应”, 所以本文选择上证综指作为研究对象。借鉴文献 [18] 的结论, 在避免市场微观结构带来严重噪声的基础上, 选择尽可能高频率的数据, 因此本文选择上证综指 5 分钟高频数据, 取样区间为 2016 年 1 月 4 日—2018 年 12 月 28 日, 共有 35 088 个数据, 数据来源于 Wind 资讯金融数据库。

3.2 统计特征与分布检验

对上证综指的 RRV 进行基本统计特征分析与检验, 相关结果如下表所示:

表 1 上证综指 RRV 的描述性统计与检验

	均值	标准差	偏度	峰度	Jarque-Bera
RRV	0.000 021	0.000 030	4.779 59	31.431 62	33 066.894 (0)
ln RRV	-11.170 240	0.840 570	0.511 29	0.305 24	34.990 (0)

从表中可以得知, 上证综指 RRV 与 ln RRV 序列偏度大于 0, 呈现出右偏的趋势; 同时峰度大于 0, 表现为尖峰特征。总体而言, 呈现出有偏、尖峰厚尾的特征, 结合 Jarque-Bera 结果可知, 整体并不服从正态分布。尝试利用 QQ 图对 ln RRV 整体是否服从有偏 t 分布进行判断, 结果见图 1。

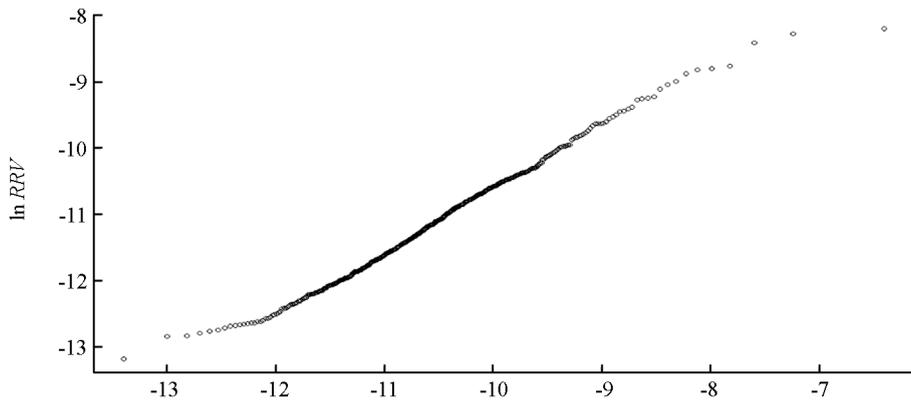


图 1 上证综指 ln RRV 基于有偏 t 分布的 QQ 图

从有偏 t 分布下的 QQ 图可以得知, ln RRV 的对应点基本构成一条直线, 因此本文选取有偏 t 分布作为假设分布。

3.3 双长记忆性与异方差性检验

对上证综指 ln RRV 序列进行单位根检验, 结果如下表所示:

表 2 上证综指 ln RRV 单位根检验

	ADF 检验	KPSS 检验
ln RRV	-3.9914 (<0.01)	1.5178 (<0.01)

从表 2 可以看出, ADF 检验结果表明序列平稳, 而 KPSS 检验显示序列并不平稳, 根据文献 [19] 对

ADF 结合 KPSS 检验的研究, 可以得知上证综指 $\ln RRV$ 序列平稳, 同时具有一定的长记忆性.

对 $\ln RRV$ 序列自相关性进行分析, 结果如图 2 所示. 从图 2 中可以看出序列的自相关函数以非常缓慢的速度衰减, 根据文献 [19] 对长记忆性与自相关系数的研究, 可以认为序列具有较强的长记忆性.

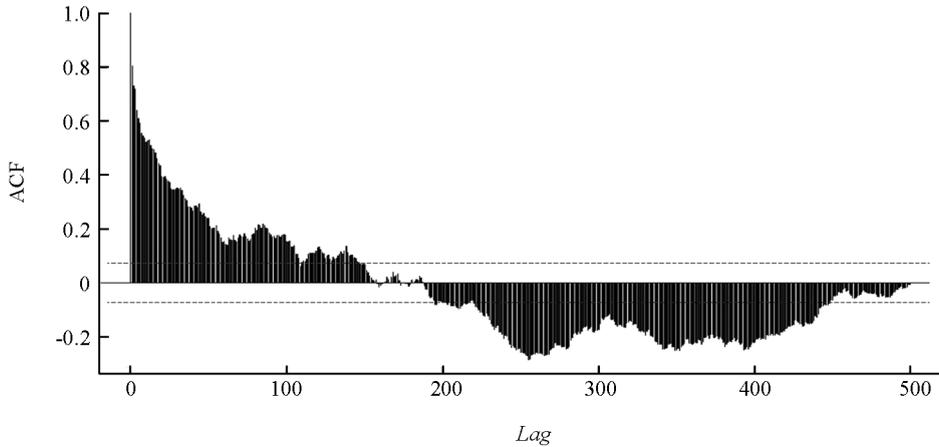


图 2 上证综指 $\ln RRV$ 序列自相关图

对上证综指 $\ln RRV$ 进行 R/S 检验得到 Hurst 指数, 进而判断序列长记忆性的强弱, 检验结果如图 3, 4 所示.

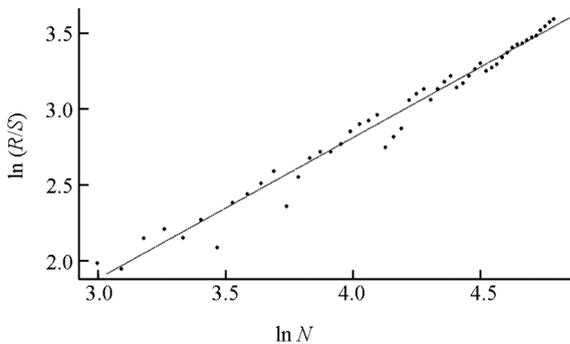


图 3 上证综指 $\ln RRV$ 的 R/S 检验图

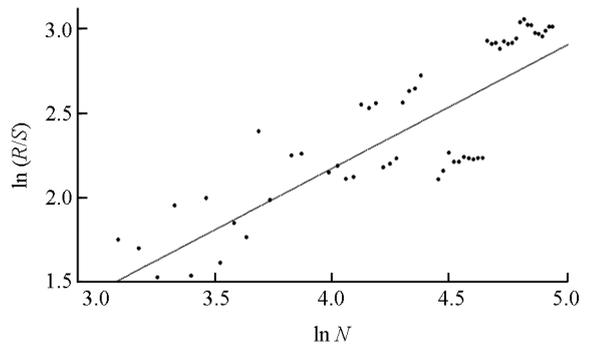


图 4 拟合残差的 R/S 检验图

R/S 检验结果表明 Hurst 指数 $H=0.928 2$, $R\text{-Squared}=0.976 5$, 同时结合图 3, 可知拟合效果良好, 并且 Hurst 指数远大于 0.5 且接近于 1, 因此可以判断上证综指的 $\ln RRV$ 序列具有很强的长记忆性, 这与前面的分析结果完全一致.

由于 Hurst 指数与 d 近似存在 $d=H-0.5$ 的关系, 则 $d \approx 0.428 2$. 对 ARFIMA-M-RRV 模型进行拟合, 并对拟合残差进行异方差性检验与长记忆性检验, 来判断是否适用于 FIGARCH 族模型, 检验结果见表 3.

表 3 异方差性检验 (ARCH 检验)

Lag	1	2	3	4
P. Value	0.014 4	0.134 5	0.023 1	0.058 1

结合表 3 可以得知, 在滞后阶数分别为 1, 3, 4 阶, 显著性水平为 10% 时均拒绝原假设, 即认为 $\ln RRV$ 的波动率并非常数, 存在较强异方差性.

针对拟合残差的 R/S 检验结果表明 Hurst 指数 $H=0.732$, $R\text{-Squared}=0.650$, 同时结合图 4 可以得知拟合效果较好, 并且 Hurst 指数大于 0.5, 因此可以判断波动率同样具有长记忆性.

结合上述分析可知上证综指的 $\ln RRV$ 具有异方差性和双长记忆性的特征, 因此结合 FIGARCH 族对 ARFIMA-M-RRV 建立双长记忆模型.

3.4 模型的建立与参数估计

对 $\ln RRV$ 序列进行 0.428 2 阶差分, 并对分数阶差分后的 $\ln RRV$ 序列测算其自相关以及偏相关系数, 对自回归与移动平均项进行定阶, 测算结果如下表所示:

表 4 分数阶差分后 $\ln RRV$ 序列的 ACF 与 PACF

Lag	1	2	3	4	5	6	7	8	9
ACF	-0.122	-0.103	0.094	-0.122	-0.032	0.055	-0.066	-0.017	0.008
PACF	-0.446	-0.031	-0.001	0.048	-0.056	0.002	0.000	-0.016	0.010

对于自相关系数, 存在

$$|\hat{\rho}_k| \leq \frac{2}{\sqrt{N}} (1 + 2 \sum_{i=1}^k \hat{\rho}_i^2)^{\frac{1}{2}} = 0.128 \quad k = 1, 2, 3, \dots \quad (9)$$

对于偏相关系数, 存在

$$|\hat{\phi}_{kk}| \leq \frac{2}{\sqrt{N}} = 0.073 \quad k = 2, 3, 4, \dots \quad (10)$$

根据 Box-Jeins 定阶理论, 可以确定模型的自回归阶数为 1, 移动平均阶数为 0, 即模型为 ARFIMA-M-RRV (1, 0) 模型. 同时, 确定 ARCH 与 GARCH 阶数均为 1 阶.

分别针对 FIGARCH (CHUNG), FIEGARCH 以及 HYGARCH 建立基于 ARFIMA-M-RRV 的双长记忆模型, 并利用基于 BHHH 算法的极大似然估计对参数进行估计, 参数估计结果见表 5.

表 5 偏 t 分布下各模型估计结果

模型	FIGARCH	FIEGARCH	HYGARCH
$Cst (M)$	-11.411 4	-9.814 9	-11.355 0
	(0.000 0)	(0.000 0)	(0.000 0)
AR (1)	-0.121 9	-0.171 8	-0.137 5
	(0.000 0)	(0.063 5)	(0.000 0)
b	0.029 1	0.024 5	0.032 5
	(0.000 0)	(0.0001)	(0.000 0)
c	-0.035 3	-0.032 3	-0.032 8
	(0.000 0)	(0.0004)	(0.000 0)
d_1	0.476 7	0.554 5	0.484 6
	(0.000 0)	(0.000 0)	(0.000 0)
$Cst (V)$	0.171 1	0.000 1	0.099 6
	(0.000 0)	(1.000 0)	(0.000 0)
ARCH	0.000 0	0.155 9	0.001 7
	(1.000 0)	(0.842 9)	(0.000 0)
GARCH	0.121 8	0.751 0	0.175 5
	(0.000 0)	(0.006 0)	(0.000 0)
d_2	0.107 9	0.155 5	0.295 5
	(0.000 0)	(0.638 6)	(0.000 0)
ξ	0.639 0	0.636 5	0.605 0
	(0.000 0)	(0.000 0)	(0.000 0)

续表 5

模型	FIGARCH	FIEGARCH	HYGARCH
v	7.679 1 (0.000 0)	8.144 5 (0.062 5)	6.803 5 (0.000 0)
EGARCH (θ_1)		0.162 1 (0.415 1)	
EGARCH (θ_2)		0.083 4 (0.616 6)	
$\ln\alpha$			-0.625 6 (0.000 0)
AIC	8.453 4	12.514 0	10.464 6
HQ	7.319 3	11.148 7	9.213 1

结合表 5 中的模型参数估计结果, 可以发现:

1) FIEGARCH 中的杠杆项参数均不显著, 这恰巧说明了均值方程引入的杠杆项比较完美地刻画了 $\ln RRV$ 的杠杆效应, 进而导致方差方程杠杆项并不显著. 同时 d_1 以及 AR (1) 的估计结果同样不显著, $d_1 > 0.5$, 表明 FIEGARCH 的参数估计效果较差.

2) HYGARCH 与 FIGARCH 关于 d_1 的估计值均接近于 0.5, 体现了 $\ln RRV$ 很强的长记忆性, 同时 $d_2 > 0$ 且不太接近 0.5, 体现了波动率较强的长记忆性, 这与前文研究结果完全一致.

3) FIEGARCH 的 AIC 与 HQ 值均大于其他 2 种模型, 而 HYGARCH 与 FIGARCH 的 AIC 与 HQ 值相对较小, 另外 FIGARCH 的 ARCH 项并不显著, 因此 FIGARCH 与 HYGARCH 能更好地对波动率的异方差性进行描述, 但 HYGARCH 略优于 FIGARCH.

3.4 VaR 计算与检验

通过 $VaR_t = u_t + skst_\alpha \sqrt{RRV_t}$ 对 HYGARCH 与 FIGARCH 下的 VaR 进行计算, 并对计算结果进行失败率检验与动态分位数检验, 以验证模型的优劣, 计算与检验结果见表 6, 7 与图 5.

表 6 失败率检验结果

模型	分位数	成功率	Kp 统计量	p 值
FIGARCH	0.950 0	0.954 7	0.364 5	0.546 0
	0.975 0	0.978 8	0.998 9	0.312 0
	0.990 0	0.989 0	0.065 7	0.797 6
	0.995 0	0.991 7	1.272 0	0.259 4
	0.997 5	0.993 1	3.742 4	0.053 0
HYGARCH	0.950 0	0.953 4	0.184 3	0.667 2
	0.975 0	0.975 3	0.003 5	0.952 6
	0.990 0	0.9890 4	0.065 7	0.797 6
	0.995 0	0.9917 8	1.272 0	0.259 4
	0.997 5	0.9958 9	0.634 0	0.431 2

表 7 动态分位数检验结果

模 型	分位数	统计量	p 值
FIGARCH	0.950 0	12.74 0	0.047 4
	0.975 0	3.024 1	0.805 8
	0.990 0	0.452 3	0.998 4
	0.995 0	1.148 5	0.979 4
	0.997 5	2.189 3	0.901 5
HYGARCH	0.950 0	7.657 4	0.439 8
	0.975 0	2.628 2	0.853 9
	0.990 0	0.452 3	0.998 4
	0.995 0	1.148 5	0.979 4
	0.997 5	0.507 1	0.997 8

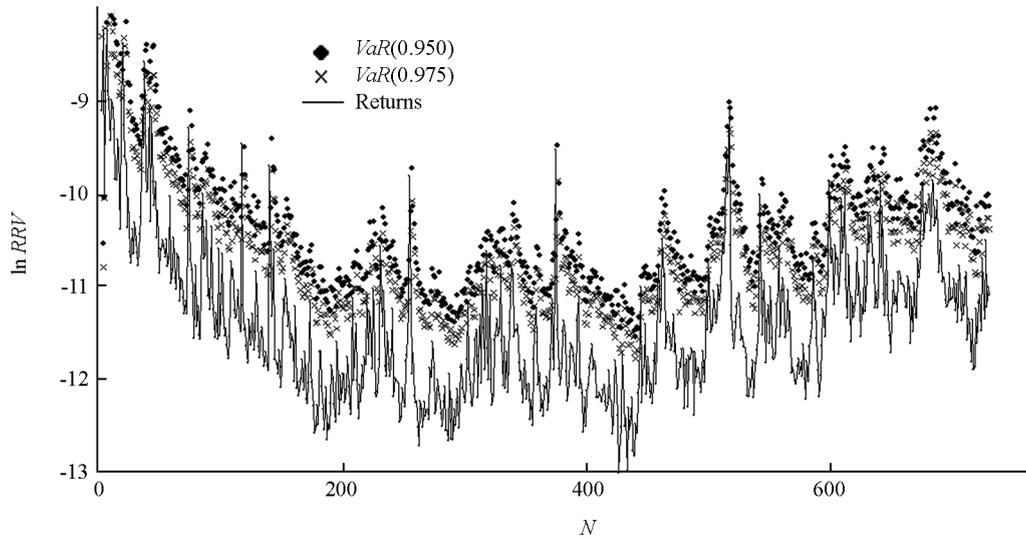


图 5 HYGARCH 模型 VaR (0.950; 0.975) 图

结合 VaR 的计算与检验结果可以发现:

1) 失败率检验中, HYGARCH 在 0.950 0, 0.975 0 以及 0.997 5 分位数下的成功率相对于 FIGARCH 而言更接近对应的分位数, p 值同样更优于 FIGARCH, 尤其在 0.997 5 分位数下 FIGARCH 对应的 p 值仅为 0.053 0, 检验结果非常不理想, 反观 HYGARCH 在 0.997 5 分位数下 p 值为 0.431 2, 能更好地对极端风险进行控制。

2) 动态分位数检验中, FIGARCH 在 0.950 0, 0.975 0 以及 0.997 5 分位数下的 p 值均小于 HYGARCH, 尤其是在 0.950 0 分位数下的 p 值仅有 0.047 4, 效果非常不理想, 远低于 HYGARCH 对应的 0.439 8, 这表明在动态分位数检验下 HYGARCH 同样能更好地对极端风险进行控制。

综上所述, HYGARCH 对于 ARFIMA-RRV 模型 VaR 的估计效果更好, 能够更好地适应和控制股票市场的极端风险。

4 结 论

本文在高频信息的基础上, 引入 RRV, 结合杠杆效应, 对双长记忆性进行识别并建立相应的模型, 对模型的 VaR 进行计算与检验, 得到了以下结论:

1) 上证综指 ln RRV 序列具有尖峰厚尾的特征, 结合 Jarque-Bera 检验以及 QQ 图, 可以得知整体服从

有偏 t 分布.

2) 结合单位根检验, 自相关图检验, 异方差检验以及 R/S 检验可知上证综指 $\ln RRV$ 序列具有双长记忆性的特征.

3) 对 FIGARCH, FIEGARCH 以及 HYGARCH 下的 ARFIMA-M-RRV 模型进行拟合, 结果表明 FIGARCH 与 HYGARCH 拟合结果较好, 其中 HYGARCH 略优于 FIGARCH.

4) 对 FIGARCH 与 HYGARCH 下的 ARFIMA-M-RRV 模型进行 VaR 的失败率检验与动态分位数检验, 结果表明 HYGARCH 能更好地刻画上证综指 $\ln RRV$ 序列在极端风险下的 VaR .

由实证结果可知, 针对上证综指可以建立有偏 t 分布下的 ARFIMA-M-RRV-HYGARCH 模型来对极端风险下的 VaR 进行度量与控制, 从而实现更有效的金融风险管理.

参考文献:

- [1] BHATTACHARYYA M, RITOLIA G. Conditional VaR Using EVT-towards a Planned Margin Scheme [J]. International Review of Financial Analysis, 2008, 17(2): 382-395.
- [2] 黄 骥, 许学军. 基于 VaR-GARCH 的开放式基金投资风格研究 [J]. 区域金融研究, 2009(4): 55-56.
- [3] 严伟祥, 张 杰. 基于 GARCH-VaR 模型的对冲基金市场风险度量研究 [J]. 经济与管理评论, 2013, 29(5): 78-83.
- [4] 王春峰, 张庆翠. 中国股市波动性过程中的长期记忆性实证研究 [J]. 系统工程, 2004, 22(1): 78-83.
- [5] 马 跃. 基于 ARFIMA-GARCH-F 模型对重庆市空气质量指数动态 VaR 极值的研究 [D]. 重庆: 西南大学, 2017.
- [6] WU P T, SHIEH S J. Value-at-Risk Analysis for Long-Term Interest Rate Futures: Fat-Tail and Long Memory in Return Innovations [J]. Journal of Empirical Finance, 2007, 14(2): 248-259.
- [7] 王吉培, 旷志平. 偏态 t 分布下 FIGARCH 模型的动态 VaR 计算 [J]. 统计与信息论坛, 2009, 24(5): 75-79.
- [8] 王宣承, 陈 艳. 基于 ARFIMA-FIGARCH 模型的利率市场风险度量 [J]. 统计与信息论坛, 2014, 29(6): 40-47.
- [9] ANDERSEN T G, BOLLERSLEV T. Answering the Skeptics: Yes, Standard Volatility Models do Provide Accurate Forecasts [J]. International Economic Review, 1998, 39(4): 885.
- [10] KOOPMANS J, JUNGBACKER B, HOL E. Forecasting Daily Variability of the S&P 100 Stock Index Using Historical, Realised and Implied Volatility Measurements [J]. Journal of Empirical Finance, 2005, 12(3): 445-475.
- [11] 杨 科, 田凤平. 结构突变条件下农产品期货市场波动率的预测 [J]. 中山大学学报(自然科学版), 2014, 53(2): 59-72.
- [12] CHRISTENSEN K, PODOLSKIJ M. Realized Range-Based Estimation of Integrated Variance [J]. Journal of Econometrics, 2007, 141(2): 323-349.
- [13] 唐 勇, 张世英. 已实现波动和已实现极差波动的比较研究 [J]. 系统工程学报, 2007, 22(4): 437-442.
- [14] 赵 华. 中国股市的跳跃性与杠杆效应——基于已实现极差方差的研究 [J]. 金融研究, 2012(11): 179-192.
- [15] 赵树然, 任培民, 赵 昕. 基于 CARR-EVT 整体方法的动态日 VaR 和 CVaR 模型研究 [J]. 数量经济技术经济研究, 2012, 29(11): 130-148.
- [16] BAILLIE R T, BOLLERSLEV T, MIKKELSEN H O. Fractionally Integrated Generalized Autoregressive Conditional Heteroskedasticity [J]. Journal of Econometrics, 1996, 74(1): 3-30.
- [17] DAVIDSON J. Moment and Memory Properties of Linear Conditional Heteroscedasticity Models, and a New Model [J]. Journal of Business & Economic Statistics, 2004, 22(1): 16-29.
- [18] BOLLERSLEV T, LITVINOVA J, TAUCHEN G. Leverage and Volatility Feedback Effects in High-Frequency Data [J]. Journal of Financial Econometrics, 2006, 4(3): 353-384.
- [19] LEE D, SCHMIDT P. On the Power of the KPSS Test of Stationarity Against Fractionally-Integrated Alternatives [J]. Journal of Econometrics, 1996, 73(1): 285-302.