

人民币汇率的双成分混合波动率模型^①

姚远¹, 刘振清¹, 翟佳², 曹弋³

(1. 河南大学管理科学与工程研究所, 开封 475004; 2. 索尔福德大学商学院, 英国 索尔福德 M5 4WT;
3. 爱丁堡大学商学院, 英国 爱丁堡 EH1 1LT)

摘要: 汇率波动性预测在金融和计算领域一直受到广泛关注, 然而由于缺乏可以捕捉汇率波动动态变化的预测模型, 高频汇率的波动率预测至今没有得到彻底的研究. 文章提出了基于神经网络的双成分混合汇率波动率模型, 该模型利用低通 Hodrick-Prescott 滤波器将已实现波动率分解为长期分量和短期分量, 使用自回归神经网络模拟长期分量, 一阶自回归过程模拟短期分量. 通过实证分析确定自回归神经网络参数(10个隐神经元和四阶滞后输入神经元), 以6种主要高频汇率(英镑/人民币, 美元/人民币, 澳元/人民币, 欧元/人民币, 日元/人民币, 和瑞士法郎/人民币), 在5 h(d)、20 h(d)、100 h(d)、200 h(d)、360 h(d)和500 h(d)的预测区间构建1 h和1 d已实现波动率, 并与双成分 GARCH 模型、EGARCH 模型、四阶滞后自回归神经网络模型3个基准模型进行对比, 分析模型的预测性能, 实验评估表明, 提出的混合预测模型在所有预测的范围内均显著地优于传统人民币汇率波动模型.

关键词: 已实现波动率; 汇率; 人工神经网络; 成分 GARCH; HP 滤波器

中图分类号: F830 **文献标识码:** A **文章编号:** 1007-9807(2019)11-0091-15

0 引言

我国的汇率制度经历了创新和探索的阶段, 1994年开始实施浮动汇率制度, 2005年7月对人民币汇率形成机制进行改革, 人民币汇率不再盯住单一美元, 而是选择若干种主要货币组成货币篮子, 参考一篮子货币计算人民币多边汇率指数的变化, 实行以市场供求为基础、参考一篮子货币进行调节、有管理的浮动汇率制度, 自此人民币升值2%. 2008年全球金融危机爆发后, 人民币一直面临着不断升值的压力. 由于人民币价格的整体波动对国家和全球经济将产生巨大影响, 因此, 如何提高预测人民币价格波动率的预测精度一直是学术界和实务界亟待解决的问题. 无论对人民币定价、投资, 还是风险管理, 波动率都是重要的指

标, 也被认为是“金融市场和经济脆弱性的晴雨表”^[1-2]. 因此, 为我国外汇市场提供可靠、有效的外汇波动率预测模型对经济发展、金融市场的稳定起到至关重要的作用.

学术界对波动率模型研究较多, 目前主要分为计量经济模型和机器学习模型两大类, 但哪种模型预测的更准确在学术界却没有达成共识^[3].

波动率通常表现为尖峰厚尾、波动聚集和杠杆效应等特性, 因此, 早期针对波动率的不同特性, 出现了一系列 ARCH 以及相关扩展的计量经济模型. Engle^[4]最先提出的 ARCH 模型, 假定收益率误差项服从条件期望为零和条件方差为前若干期收益率误差平方的条件正态分布, 符合金融市场的波动集群性及异方差等特征. 随后 Bollerslev^[5]提出在条件方差的解释项中引入无穷期误

① 收稿日期: 2018-02-09; 修订日期: 2019-03-14.

基金项目: 国家社会科学基金资助项目(17BJY194); 河南大学哲学社会科学重大项目培育计划资助项目(2019ZDXM016).

作者简介: 姚远(1975—), 女, 河南开封人, 博士, 教授, 博士生导师, Email: yaoyuan@henu.edu.cn

差项的 GARCH 模型^[6] 以及多元 GARCH 模型. Engle 等^[7] 将风险引入模型, 解释高风险 - 高收益问题, 提出 GARCH-M 模型. 为了克服波动率对称性的限制, 体现收益率正向波动和负向波动的不同, Nelson^[8] 提出 EGARCH 模型, Glosten 等^[9] 和 Zakoian^[10] 提出 TGARCH 模型. 前者对不同的信息加权, 后者则对负向信息增加指示变量, 用以显示非对称波动. 这些 GARCH 族模型在捕捉波动率的持续性均有较为良好的表现.

随着计算机的快速发展, 基于高频数据的波动率模型也不断涌现^[11-13]. Andersen 和 Bollerslev^[14, 15] 使用外汇市场 5 min 高频交易数据, 提出已实现波动率 (realized volatility) 的概念, 并对其建模, 发现其分布具有尖峰厚尾、右偏性、均值回复性、长记忆性和跳跃性. Hansen 等^[16, 17] 与关璐和郭名媛^[18] 提出 Realized GARCH 模型, 通过加入测量方程将高频数据和隐含收益率联系起来, 实现了收益率、波动率和 RV 的联合建模. Granger^[19, 20] 提出分数差分自回归滑动平均模型 (ARFIMA) 来捕捉已实现波动率的长期记忆特征. 一些学者指出 ARFIMA 模型需要构建分数差分算子, 损失大量的交易信息, 因此提出了异质自回归已实现波动率模型 (HAR-RV), 与 ARFIMA 模型比较, HAR-RV 不仅避免了 ARFIMA 模型的复杂估计, 还成功复制出金融收益率序列的长记忆性和胖尾等“典型特征”^[21, 22]. 马峰等^[23-25] 在引入跳跃和隔夜收益率等因素后详细分析了 HAR-RV 模型的预测精度. 在这些研究中, 越来越多的学者发现波动率的结构从长期和短期两种动态趋势的叠加来预测更具优势. Engle 和 Lee^[26] 提出成分 GARCH 模型 (通常称为双成分 GARCH 模型), 该模型把股票收益的条件方差刻画的波动率分解为永久性长期趋势分量和暂时的短期分量, 分析了 1987 年 10 月的崩盘对股票波动率的影响. Brandt 和 Jones^[27] 通过双成分 GARCH 模型可以把日收益率的波动描述为一个高持久性成分和一个强稳定性成分. Harris 等^[28] 从当天汇率波动率中提取长期分量, 并对短期分量建立平稳自回归过程建模, 发现对长期分量和短期分量分别描述的模型进行的样本外预测比普通 GARCH 模型效果更好.

随着人工智能技术和大数据的发展, 基于机

器学习的各种波动率模型取得了令人瞩目的进展^[29-30]. Boyacioglu 和 Avcı^[31] 提出的自适应神经模糊推理系统 (ANFIS) 预测 Istanbul 股票市场收益的波动性. 随后, ANFIS 模型也用于预测 Zagreb 股票市场指数的收盘价格^[32]. 神经网络允许数据带有较强的噪声, 对复杂、非线性数据、趋势性序列的识别方面有出色表现. 近几年, 学者开始结合机器学习模型与计量经济模型, 建立一些混合模型, 应用于各个领域的预测. Hajizadeh 等^[33] 从 GARCH, EGARCH 和 GJR-GARCH 中提取解释变量, 再输入神经网络模型进行波动率预测, 结果显示这种混合模型预测精度明显优于传统模型. 随后, Kristjanpoller 等^[34] 设计出由神经网络和 GARCH 模型组成的混合模型进行波动率预测, 第一步用 GARCH 模型对波动性进行建模和预测, 第二步将 GARCH 的输出和原始波动性数据输入神经网络模型进行预测, 结果显示混合模型明显优于传统的 ARFIMA 和 GARCH 模型. 该混合模型也被用来预测未来石油、金银铜等重金属价格, 结果均显示比传统模型的预测精度提高了 30%^[35, 36]. Das 等^[37] 提出了结合经验模式分解 (EMD) 和快速降低核极限学习机 (KELM) 混合模型, 用来预测提前一天的外汇汇率. 目前已有的研究说明将神经网络与计量经济学模型相结合, 用于预测波动率有一定的优势.

因此, 本文在双成分 GARCH 模型的基础上, 引入三层自回归神经网络, 提出了“神经网络增强型混合波动率混合模型”, 它由低通滤波器、三层自回归神经网络和一阶自回归过程组成, 分别捕获已实现波动率^[14] 的短期和长期特征, 并进行预测. 本文的模型不同于 Kristjanpoller 等^[34] 的混合模型, 后者先用 GARCH(1, 1) 对已实现波动率做预测, 其输出和已实现波动率一起输入神经网络再次预测, 神经网络的输出作为最终已实现波动率的预测结果. 而本文首先使用低通 HP 滤波器将波动率分解为长期成分和短期成分; 其次对两成分分别建模, 由于长期成分呈现非线性平滑曲线特性, 利用自回归神经网络建模, 短期成分呈现自回归特性, 采用平稳一阶自回归模型建模, 最终得到长期成分和短期成分合成的波动率预测值; 然后, 使用 2009-09-27 ~ 2015-08-12 的英镑/人民币, 美元/人民币, 澳元/人民币, 欧元/

人民币, 日元/人民币和瑞士法郎/人民币 6 种高频人民币汇率, 样本大约包括 2 145 d, 每 10 ms 为 1 次间隔, 约 77 亿次观察, 构建混合波动率模型, 进行样本外预测; 最后, 以成分 GARCH 模型、EGARCH 模型以及神经网络模型为基准模型, 比较三者与本文提出的混合模型的预测精度, 评估 500 个时间点的表现, 500 个 1 d 波动率覆盖大约两年, 500 个 1 h 波动率覆盖大约为 50 d (日均交易 10 h)。结果显示, 在大多数情况下, 本文提出的混合模型在预测性能上优于成分 GARCH、EGARCH 模型以及神经网络模型, 预测性能的提高在长期和短期内均稳定, 与 Engle 和 Lee^[26] 与 Brandt 和 Jones^[27] 的研究结果一致。特别要指出的是, 本文模型预测精度在所有时间范围内基本一致, 在长期成分预测中, 对比双成分 GARCH 模型和 EGARCH 模型的表现更为明显, 总体来讲, 实验评估表明本文提出的模型比大多数传统的波动率模型具有更稳定、更好的预测性能。

本文提出的混合预测模型显式定义和计算波动率的长短期成分, 摒弃了长期成分的“自回归假设”, 利用神经网络为长期成分的复杂非线性特性建模, 得到了更好的预测效果, 进一步证明了 Engle 和 Lee^[26] 的多成分理论在人民币汇率波动率中的适用性。

1 模型设计

1.1 模型结构

成分 GARCH 模型把波动视为由长期趋势成分和短期趋势成分组成, 假设两者均遵循均值回归方程, 长期趋势均值回复速度慢, 短期趋势均值回复速度快。本文提出的基于神经网络的双成分混合模型不同于传统的成分 GARCH 模型, 传统模型仅使用 1 个均值回归模型把长期和短期两种成分描述出来, 本文则通过 4 步, 建立基于自回归神经网络的双成分混合波动率模型, 使用已实现波动率^[14] 描述高频汇率波动的长期和短期动态性, 并进行预测。

假定已实现波动率遵循下面给出的双成分过程

$$\sigma_t = L_t + S_t \quad (1)$$

$$S_t = \alpha S_{t-1} + \varepsilon_t \quad (2)$$

式中 L_t 和 S_t 分别是已实现波动率的长期分量和短期分量; α 是衡量短期分量回归速度的参数; ε_t 是具有零均值和常数方差的随机误差项。短期分量 S_t 结构沿用文献 [28] 所用的一阶自回归过程, 即 AR(1) 模型。

本文提出的模型由 4 步构造实现。

第 1 步, 使用低通 HP 滤波器从已实现波动率中分解和抽取长期分量 L_t , 则短期分量由 $S_t = \sigma_t - L_t$ 得到;

第 2 步, 使用长期分量 L_t 来训练人工神经网络 (ANN) 以获得预测模型, 时刻 $t+n$ 的 L_{t+n} 值由训练得到的 ANN 来预测;

第 3 步, 沿用文献 [28] 的短期成分模型: 用 AR(1) 过程模型 $S_t = \alpha S_{t-1} + \varepsilon_t$, 从第 1 步获得的短期分量 S_t 进行估计, 通过估计的 AR(1) 来预测在时刻 $t+n$ 的 S_{t+n} 值;

第 4 步, 通过 $\sigma_{t+n} = L_{t+n} + S_{t+n}$ 预测时刻 $t+n$ 的波动率。

1.2 抽取长期分量

经济学和金融学中常使用 HP 滤波器来从原始数据中消除时间序列的短期周期分量^[38]。因此, 第 1 步使用 HP 低通滤波器从时间序列中提取低频非线性分量, 用低频分量代表已实现波动率中的长期分量 L_t 。对于给定的汇率序列 y_t , HP 滤波器把 y_t 分解为长期趋势分量 τ_t 、短期周期性分量 c_t 和误差项 ε_t , 即

$$y_t = \tau_t + c_t + \varepsilon_t \quad (3)$$

对于给定平滑参数 λ 值, 则长期趋势分量 τ_t 可以求解下式得到

$$\min \tau_t = \min_{\tau} \left(\sum_{t=1}^T (y_t - \tau_t)^2 + \lambda \sum_{t=2}^{T-1} [(\tau_{t+1} - \tau_t) - (\tau_t - \tau_{t-1})]^2 \right) \quad (4)$$

式中 λ 为平滑参数, 其控制短期震荡趋势增长率的变化, λ 值越大, 对时间序列的二阶差分的抵消就越大, 即对短期变化的抵消越大, 故所得到的曲线更平滑。本文使用常用计算 λ 值的方法^[28, 39, 40], 1 h 现实波动率的 $\lambda = 100 \times (360 \times 8)^2 = 829\,440\,000$ (每年 360 个交易日, 每天 8 h); 1 d 现实波动率的 $\lambda = 100 \times 360^2 = 12\,960\,000$ (每年 360 个交易日)。

1.3 神经网络预测长期分量

第 2 步,使用三层 4 阶滞后自回归神经网络预测已实现波动率的长期分量 L_t . 自回归神经网络(ARXNN) 是人工神经网络的特殊结构,在调整趋势(从原始时间序列中去除短期分量)之后,可以明显减少预测误差^[41-42]. 其中三层自回归的神经网络模型性能最好^[43-44]. 因此,采用三层自回归神经网络(ARXNN): 包括输入滞后 L_t 神经网络的输入层、具有双曲线正切激活函数的隐藏层和具有线性激活函数的输出层,预测已实现波动率的长期分量 L_t ,按照式(5)进行一阶预测^[44]

$$\hat{L}_t(\theta_{\text{ARXNN}}) = g[\varphi_i(t), \theta_{\text{ARXNN}}] \\ = F_j \sum_{u=1}^{N_h} W_{j,u} f_u \left(\sum_{i=1}^{N_u} \varphi_i(t) w_{u,i} + w_{u,\rho} \right) + W_{j,\rho} \quad (5)$$

式中 $g[\varphi_i(t), \theta_{\text{ARXNN}}]$ 是自回归神经网络(ARXNN) 定义的函数; N_h 是隐藏单元的数量; N_u 是输入变量的数量; $W_{j,u}$ 是隐藏神经元到输出层的权向量; $w_{u,i}$ 表示从外部输入 N_u 到隐藏单元 N_h 的权重矩阵; $\varphi_i(t)$ 是神经网络 ARX 部分的回

归参数向量; θ_{ARXNN} 是参数向量,包含自回归神经网络(ARXNN) 的所有可调参数.

采用广泛使用的 ARXNN 参数配置^[45],输入层采用 4 个滞后 $t-1, t-2, t-3, t-4$ 作为输入,即 $N_u = 4$; 隐藏层神经元数目在一定程度上(神经元数目通常会选择 5~20 之间) 决定神经网络对非线性回归的映射学习能力,因此为了达到最优学习效果,且在一定程度上避免过度拟合,用 $N_h = 5, 10, 15$ 等 3 种不同的神经元数目,采用交叉校验(cross-validation) 确定最终的 N_h 值(后续实验中得到的结论是 $N_h = 10$ 可以达到最优,且避免过度拟合); 每一个隐藏层神经元内包含 1 个双曲正切激活函数 f_u ,输出层 F_j 为线性累加函数; 神经网络参数优化采用改良的 Levenberg-Marquardt (LM) 算法,该算法在时间容量和准确性方面更高效^[46]. 本文的模型结构如图 1 所示. 输入层包含 4 个神经元 $N_u = 4$, 分别接收 4 个滞后作为延迟输入. 隐藏层包含 $N_h = 10$ 个神经元,结构中 $w_{u,i}, W_{j,u}$ 是模型通过训练优化确定的权重参数. 结构图中的“+”表示累加,即把隐藏层的所有神经元计算结果加权累加作为模型最终输出.

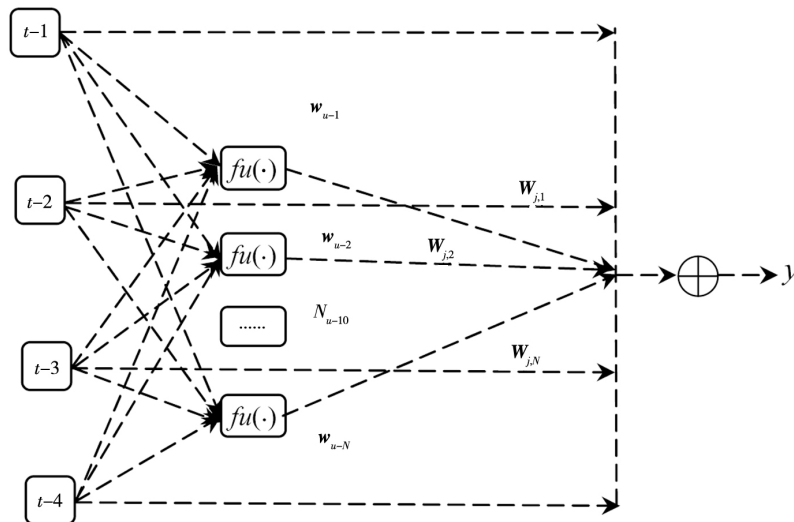


图 1 三层自回归神经网络结构图

Fig. 1 Structure of three-layer autoregressive neural network

图 2 显示使用 ARXNN 模型预测从 2012-12-07~2013-02-05 的实现英镑/人民币(GBP/CNY) 汇率波动率的长期分量 L_t 的例子,图 1 的 ARXNN 模型是用 10 个神经元的隐藏层构建的,

使用 2009-09-27~2012-12-06 GBP/CNY 汇率波动率的 L_t 进行训练,预测结果 \hat{L}_t 包括从 2012-12-07~2013-02-05 的 GBP/CNY 汇率波动率的 1 000 个长期分量值.




图 2 使用 ARXNN 预测的 GBP/CNY 的样本外长期分量 L_t 的示例
 Fig. 2 Example of long term component L_t forecasting of GBP/CNY out-of-sample using ARXNN.

图 2 (a) 给出 2012 - 12 - 07 ~ 2013 - 02 - 05 由 HP 滤波器提取的 GBP / CNY 的长期分量 L_t ; 图 2 (b) 给出采用 ARXNN 模型预测的 2012 - 12 - 07 ~ 2013 - 02 - 05 期间 GBP / CNY 长期分量的预测值 \hat{L}_t ; 图 2 (c) 给出 GBP / CNY 长期分量与预测分量之间的差异 $\hat{L}_t - L_t$. 可以发现样本外的预测误差约为 10^{-8} .

1.4 自回归模型预测短期分量

第 3 步, 延用文献 [28], 仍然使用一阶自回归模型 $S_t = \alpha S_{t-1} + \varepsilon_t$ 估计短期分量 S_t . 由此给出短期分量 S_t 的 n 步提前预测

$$\hat{S}_{t+n} = \alpha^n S_t + \sum_{i=1}^{n-1} \alpha^i \varepsilon_{t+i} \quad (6)$$

通过 ARXNN 预测已实现波动率的长期分量 \hat{L}_{t+n} 则由式 (1) 给出已实现波动率的 n 步提前预测

$$\hat{\sigma}_{t+n} = \hat{L}_{t+n} + \hat{S}_{t+n}$$

2 数据与评估

2.1 数据

使用第 1 部分定义的双成分神经网络双成分混合波动率模型, 预测 AUD/CNY、EUR/CNY、

GBP/CNY、JPY/CNY、USD/CNY 和 CHF/CNY (澳元/人民币、欧元/人民币、英镑/人民币、日元/人民币、美元/人民币和瑞士法郎/人民币汇率) 波动率. 原始外汇数据包括 2009 - 09 - 27 ~ 2015 - 08 - 12, 2 145 d 约 77 亿高频观测值, 该数据 (Tick 数据) 从 Oricode 公司获得. 为避免过度高频市场数据所带来的市场噪声, 对所获得的原始数据重新降频采样 (down-sampling). 根据 Andersen 和 Bollerslev^[14, 15] 的研究, 选择采样周期为 5 min, 降频采样后, 每种汇率平均观测值约为 310 000 个左右.

在接近零的时间间隔内, 当日收益的平方和 (已实现波动率) 收敛于未观测到的真实波动率. 因此, 本文未观测到的真实波动率可以通过计算日内收益的已实现波动率 (RV) 来替代^[28], 即

$$\hat{\sigma}_{rv,t}^2 = \sum_{n=1}^N r_{t,n}^2 \quad (7)$$

式中 $\hat{\sigma}_{rv,t}^2$ 是时间 t 的已实现波动率; $r_{t,n}^2$ 是区间 n ($n = 1, 2, \dots, N$) 在时间 t 的对数收益率的平方. 使用的 1 h 和 1 d 的现实波动率均由降频后 5 min 的对数收益率计算得到, 这也是本文数据中的最高频率.

1 h (或 d) 的已实现波动率通过每小时 (或天) 内汇总 12 (或 190) 个 5 min 对数收益率 $r_{t,n}^2$ 获得. 将 2009 - 09 - 27 ~ 2012 - 12 - 07 的数据 (20 000 (或 1 000) 次观测) 用于该模型的初始估计, 2012 - 12 - 08 ~ 2015 - 08 - 12 (16 681 (或 837) 次观测) 的数据用于样本外评估.

表 1 和表 2 分别给出 AUD/CNY、EUR/CNY、GBP/CNY、JPY/CNY、USD/CNY 和 CHF/CNY 6 种汇率的 1 h 和 1 d 已实现波动率统计量和自相关数据. 表 1 给出了平均值、标准差、偏度和峰度及 Bera-Jarque 统计量, 表 2 给出了滞后 1 期 ~ 滞后 6 期已实现波动率的自相关系数和 Ljung-Box Q 统计量, 括号中为对应的 p 值. 观察 Ljung-Box Q 统计量, 1 h 和 1 d 的已实现波动率均拒绝了非自相关的零假设, 因此, 判断 1 h 和 1 d 的实际波动率都是高度自相关的.

表 1 数据相关统计量

Table 1 Summary statistics

汇率种类		平均值/ 10^{-3}	标准差/ 10^{-3}	偏度/10	峰度/ 10^2	Bera-Jarque 统计量/ 10^8
小时	AUD/CNY 1h	1.400 0	1.900 0	1.078 8	1.625 7	3.286 4
	EUR/CNY 1h	0.400 0	1.200 0	0.878 14	1.503 0	14.771
	GBP/CNY 1h	1.200 0	1.800 0	1.150 5	1.769 4	211.31
	JPY/CNY 1h	1.400 0	1.800 0	1.107 8	1.732 0	298.82
	USD/CNY 1h	0.500 0	0.900 0	1.446 7	3.203 1	9.991 9
	CHF/CNY 1h	1.200 0	1.900 0	1.005 0	1.461 8	14 592.0
日	AUD/CNY 1d	8.700 0	10.700 0	1.564 7	4.346 9	0.043 093
	EUR/CNY 1d	3.000 0	3.800 0	0.879 08	1.165 0	0.059 930
	GBP/CNY 1d	9.200 0	7.400 0	0.346 21	0.206 44	0.026 480
	JPY/CNY 1d	8.100 0	7.400 0	0.343 34	0.203 98	0.043 068
	USD/CNY 1d	9.200 0	7.400 0	0.343 40	0.214 57	0.072 752
	CHF/CNY 1d	5.600 0	4.000 0	0.389 42	0.221 92	2.349 9

表 2 数据自相关

Table 2 Autocorrelations

汇率种类		滞后期						Ljung-Box Q 统计量
		1	2	3	4	5	6	
小时	AUD/CNY 1h	0.127 1	0.078 4	0.056 1	0.045 9	0.064 1	0.054 2	592.74 (0.000)
	EUR/CNY 1h	0.166 7	0.099 6	0.085 2	0.073 4	0.078 6	0.078 3	478.33 (0.000)
	GBP/CNY 1h	0.102 5	0.078 6	0.061 4	0.036 4	0.048 8	0.042 1	385.32 (0.000)
	JPY/CNY 1h	0.127 0	0.106 4	0.070 3	0.063 3	0.091 3	0.082 5	591.63 (0.000)
	USD/CNY 1h	0.567 0	0.456 8	0.398 6	0.329 9	0.300 7	0.299 7	7 190.3 (0.000)
	CHF/CNY 1h	0.170 7	0.126 3	0.099 0	0.071 7	0.084 8	0.073 3	1 069.1 (0.000)
日	AUD/CNY 1d	0.079 5	0.026 6	0.051 9	0.028 0	0.042 1	0.187 7	11.639 (0.000 646)
	EUR/CNY 1d	0.602 6	0.301 4	0.166 7	0.171 3	0.184 2	0.303 2	462.29 (0.000)
	GBP/CNY 1d	0.116 3	0.051 3	0.079 8	0.047 3	0.017 3	0.307 2	24.884 (0.000 001)
	JPY/CNY 1d	0.070 2	0.023 4	0.032 9	0.021 2	-0.001 1	0.319 7	9.0893 (0.002 571)
	USD/CNY 1d	0.085 2	0.029 7	0.048 4	0.042 1	0.015 0	0.331 1	13.370 (0.000 256)
	CHF/CNY 1d	0.190 8	0.134 6	0.103 5	0.117 5	0.085 9	0.078 8	55.849 (0.000)

图 3 (a) 中的实线表示的是 2009 - 09 - 27 ~ 2012 - 12 - 07 GBP/CNY(英镑/人民币) 汇率的小时已实现波动率, 平滑参数 λ 为 829 440 000(假设每年 360 个交易日, 每天 8 h); 虚线表示的是由 HP 滤波器提取的小时已实现波动率中的长期分量 L_t ; 图 3 (b) 表示的是 GBP/CNY 汇率的小时已实现波动

率的短期分量; 图 3 (c) 中的实线表示的是 2009 - 09 - 27 ~ 2012 - 12 - 07 GBP/CNY 汇率的日已实现波动率, 平滑参数 λ 为 12 960 000(假设每年 360 个交易日); 虚线表示的是由 HP 滤波器提取的日已实现波动率中的长期分量 L_t ; 图 3 (d) 表示的是 GBP/CNY 汇率的日已实现波动率的短期分量。




图 3 长期分量和短期分量描述

Fig. 3 Long term component and short term component of realized volatility of GBP/CNY

2.2 预测基准

本文提出的基于神经网络的双成分波动率模型使用前 500 h 或 500 d 的 1 h 或 1 d 已实现波动率做样本外预测,同时选择双成分 GARCH 模型、EGARCH 模型、4 阶滞后自回归神经网络作为与之对比的 3 个模型,进行评估.因此,分别使用混合外汇波动率、双成分 GARCH、EGARCH、4 阶滞后自回归神经网络 4 个模型,对 1 h 和 1 d 的已实现波动率进行评估.

首先,使用 2009-09-27~2012-12-07 的前 20 000 个(数据)和 1 000 个(数据)观测值对 4 个模型进行初始估计,然后预测 $t + \tau_i$ 至 $t + \tau_{i+T}$ 区间内的波动率.用 (τ_i, τ_{i+T}) 来表示预测区间.为了充分测试模型预测的稳定性和精确性,采用滚动预测,即每次预测结束,模型的初始估计数据窗口向前滑动 1 d,用新数据重新估计模型,并计

算对相应预测区间 (τ_i, τ_{i+T}) 内的波动率.

以 $(\tau_i, \tau_{i+T}) = (100, 200)$ 为例,对 1 h 的已实现波动率而言, RMSE 将评估从第 100 h 开始(每天 10 个交易日, 100 h 即 10 d 之后)到第 200 h 为止的共 100 h 预测的平均表现;对 1 d 的已实现波动率, RMSE 评估的是第 100 天开始(即 3 个月)到第 200 天为止的共 100 天预测的平均表现.用已实现波动率的均方根误差(RMSE)来衡量模型的预测性能,如式(8)

$$RMSE = \left[\frac{1}{T} \sum_{i=1}^T (\sigma_i(\tau_i, \tau_{i+T}) - \hat{\sigma}_i(\tau_i, \tau_{i+T}))^2 \right]^{\frac{1}{2}} \quad (8)$$

在实证分析中,对所有模型在 6 个不同预测区间 (τ_i, τ_{i+T}) 的表现进行比较和评估.6 个预测区间为 3 个短期: (1, 5), (1, 20) 和 (1, 100); 3 个长期: (100, 200), (260, 360) 和 (400, 500). 预测区间含义在表 3 中详细说明.

表3 预测区间的详细说明
Table 3 Detailed description of prediction interval

区间		(τ_t, σ_{t+T})	预测含义
短期	(1, 5)	$\tau_t = 1, \sigma_{t+T} = 5$	t 期模型预测 $t+1, t+2, \dots, t+5$
	(1, 20)	$\tau_t = 1, \sigma_{t+T} = 20$	t 期模型预测 $t+1, t+2, \dots, t+20$
	(1, 100)	$\tau_t = 1, \sigma_{t+T} = 100$	t 期模型预测 $t+1, t+2, \dots, t+100$
长期	(100, 200)	$\tau_t = 100, \sigma_{t+T} = 200$	t 期模型预测 $t+100, t+101, \dots, t+200$
	(260, 360)	$\tau_t = 260, \sigma_{t+T} = 360$	t 期模型预测 $t+100, t+101, \dots, t+360$
	(400, 500)	$\tau_t = 400, \sigma_{t+T} = 500$	t 期模型预测 $t+100, t+101, \dots, t+500$

2.3 评估

图4给出了4种模型在6种不同汇率的预测区间,使用式(8)给出的1h汇率已实现波动率的均方根误差(RMSE).整体而言,本文提出

的基于神经网络的双成分混合模型在所有数据的所有预测区间都达到了更优异的预测结果,并显著好于CGARCH和EGARCH两种模型.在图3(a),(b),(c),(e)中,CGARCH和EGARCH

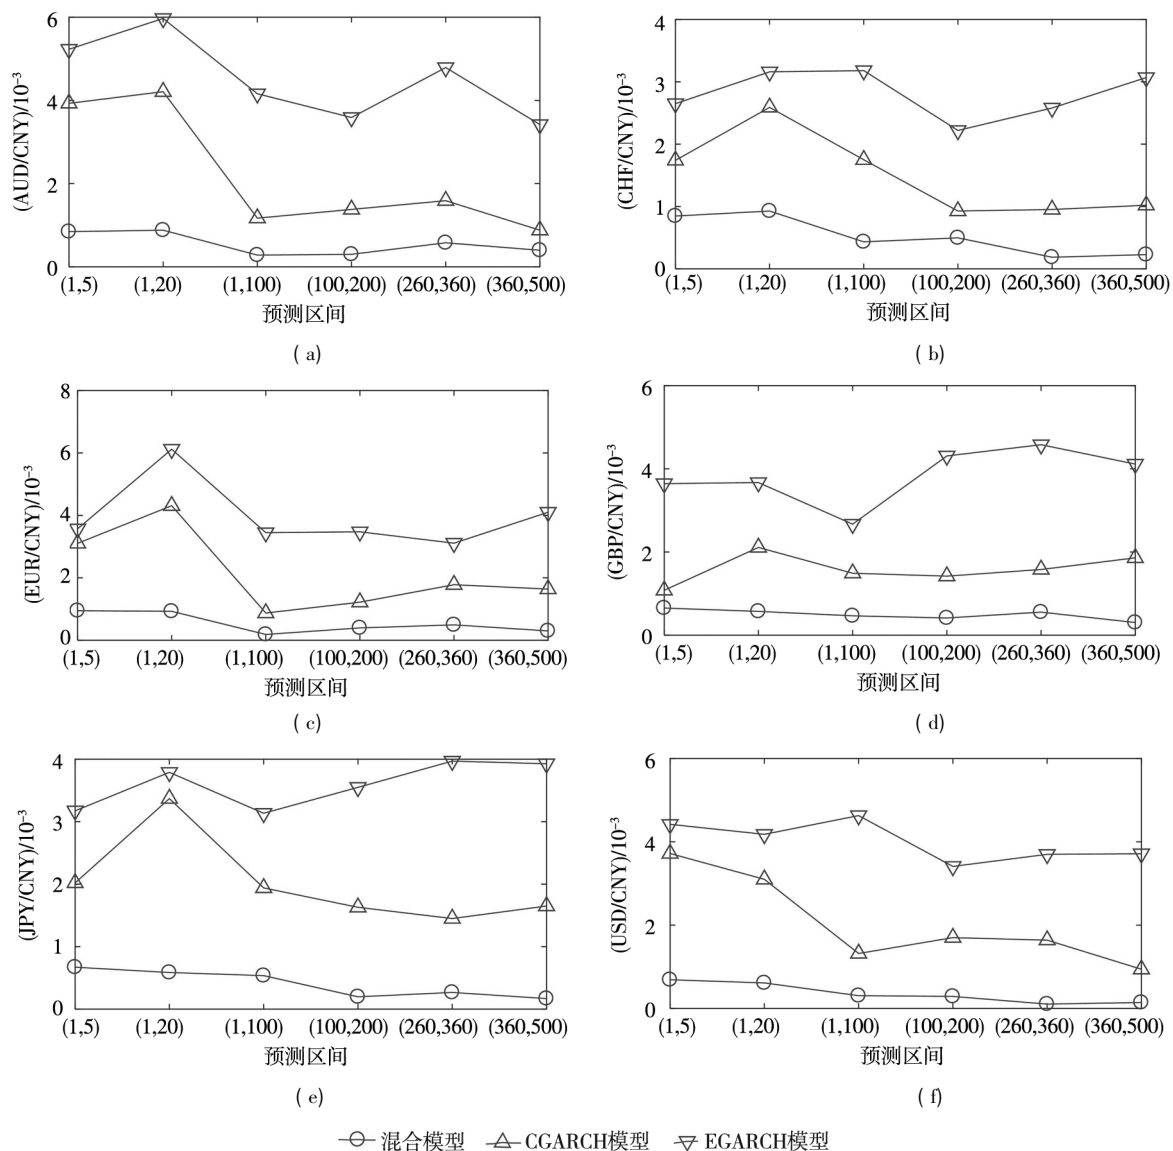


图4 6种外汇小时已实现波动率的预测结果

Fig. 4 Predicted results of in one-hour realized volatility evaluations of six exchange rates

两种模型都在(1,5)、(1,20)和(1,100)3个预测区间表现出均方根误差增大随后降低的趋势,本文认为这是由于最初的预测区间从5个时间点增加到20个,再到100个时间点,从而预测的均值更趋于稳定.而在范围(1,100)后,预测区间的长度固定为100个时间点,CGARCH基本稳定在同一误差范围内,而EGARCH模型并未表现出稳定的预测精度.本文提出的混合模型的预测误差显著低于CGARCH和EGARCH两种模型.混合模型一定程度上也表现出在(1,5)、(1,20)和(1,100)3个预测区间误差增大随后降低的趋势,但在(100,200)、(260,360)和(400,500)3个预测区间都表现出较为稳定和优异的预测精度.

图中(a)~(f)分别为澳元、欧元、英镑、美元、日元和瑞士法郎兑人民币的汇率已实现波动率预测

结果.预测采用RMSE作为度量,用 t 期模型预测 $t + \tau_1$ 至 $t + \tau_2$ 区间, $(\tau_1, \tau_{t+\tau})$ 如上述表格详述定义.

图5给出了日已实现波动率的预测结果.和图4类似,图5的实证分析采用了6种外汇汇率的日已实现波动率,对本文提出的混合模型,CGARCH和EGARCH模型进行了预测分析.3种模型的预测分析都基于 t 期模型预测 $t + \tau_1$ 至 $t + \tau_2$ 区间的波动率.如图5所示,在所有外汇数据的所有预测区间,混合模型稳定且显著优于其他模型.在个别预测区间中,混合模型的精度略接近CGARCH模型,但无一例外的优于后者.通过实证分析,发现混合模型在实证分析中达到了稳定且较优越的预测精度,主要源于神经网络对消除季节性之后的平滑非线性曲线有非常优越的预测性能,这与Nelson^[8]和Zhang和Qi^[42]的研究结果一致.

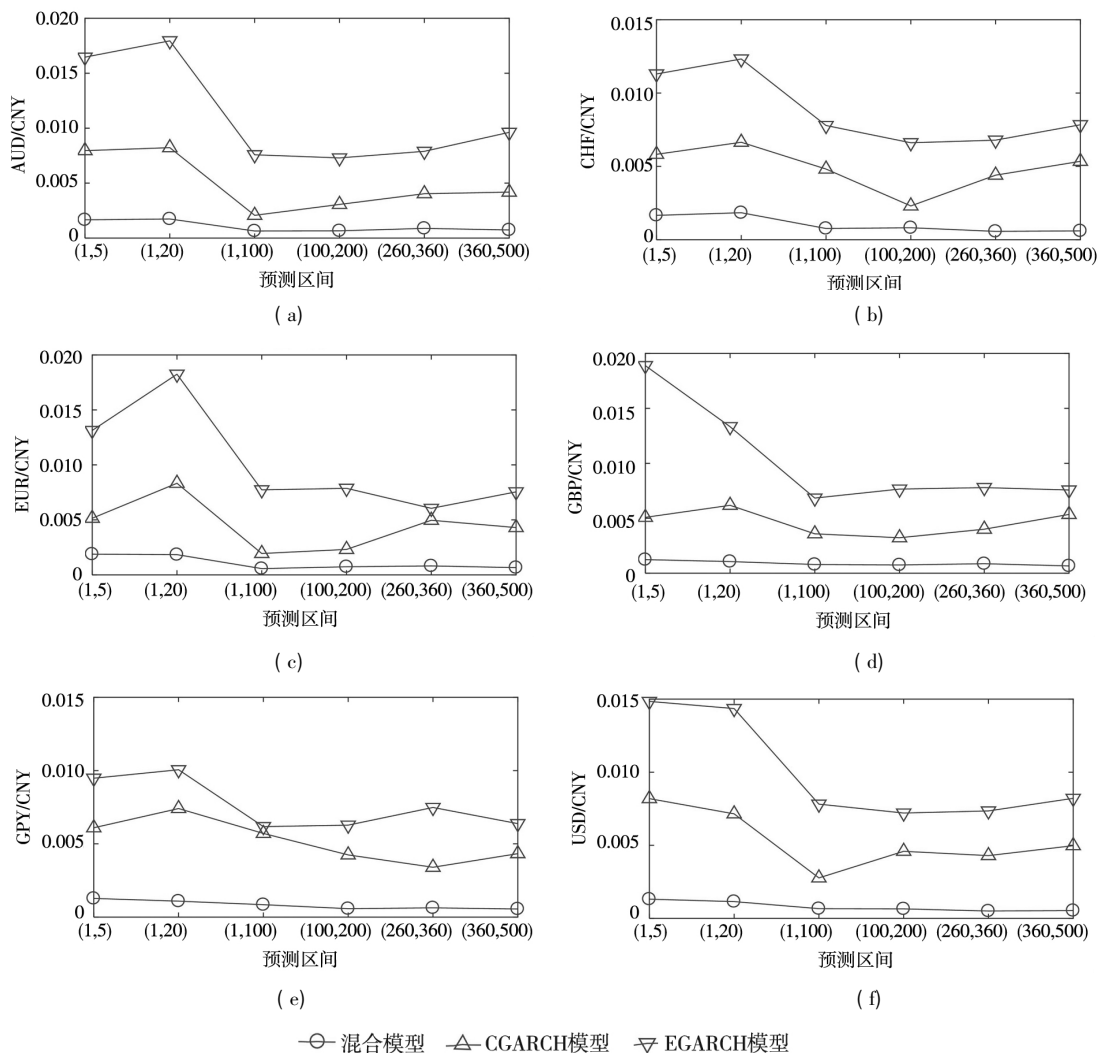


图 5 6种外汇日已实现波动率的预测结果

Fig. 5 Predicted results of in one-day realized volatility evaluations of six exchange rates

图中 (a) ~ (f) 分别为澳元、欧元、英镑、美元、日元和瑞士法郎兑人民币的汇率已实现波动率预测结果. 预测采用 RMSE 作为度量, 用 t 期 3 种模型: 混合模型、CGARCH、EGARCH, 预测 $t + \tau_1$ 至 $t + \tau_2$ 区间, $(\tau_1, \tau_{1+\tau})$ 如上述表格详述定义.

理论上讲, 三层自回归神经网络中的隐含层只要有足够数量的神经元, 就可以逼近大部分函数. 本文的隐含层中包含 10 个神经元, 为了比较神经元数量对模型的影响, 本文还测试了隐含层中包含 5 和 15 个神经元的混合模型的精度. 图 6 给出了包含 5 个、10 个和 15 个隐含层神经元的预测结果. 下图中线条代表 10 个隐含层神经元的预测结果. 本文发现在澳元兑人民币预测区间 (1, 20) 以及欧元兑人民币预测区间 (1, 5) 和 (1, 20) 之外, 剩下所有数据的预测区间, 包含 10 个隐层神经元的混合模型都取得了稳定且显著优越的预测性能. 包含 15 个隐层神经元的混合模型却并未取得显著优越性能, 可能本文提出的模型应用 15 个神经元会在平滑的成分建模中达到过拟合, 从而影响预测精度. 因此本文提出的混合模型在对外汇波动率预测中, 自回归神经网络参数选择 10 则足够获得良好预测精度. 该结论与文献 [32, 33] 的研究结论一致. 据此, 图 6 中的实验数据表明, “神经网络增强型混合双成分波动率模型”能够在具有 10 个隐藏神经元的三层自回归神经网络结构下达到最佳的预测性能.

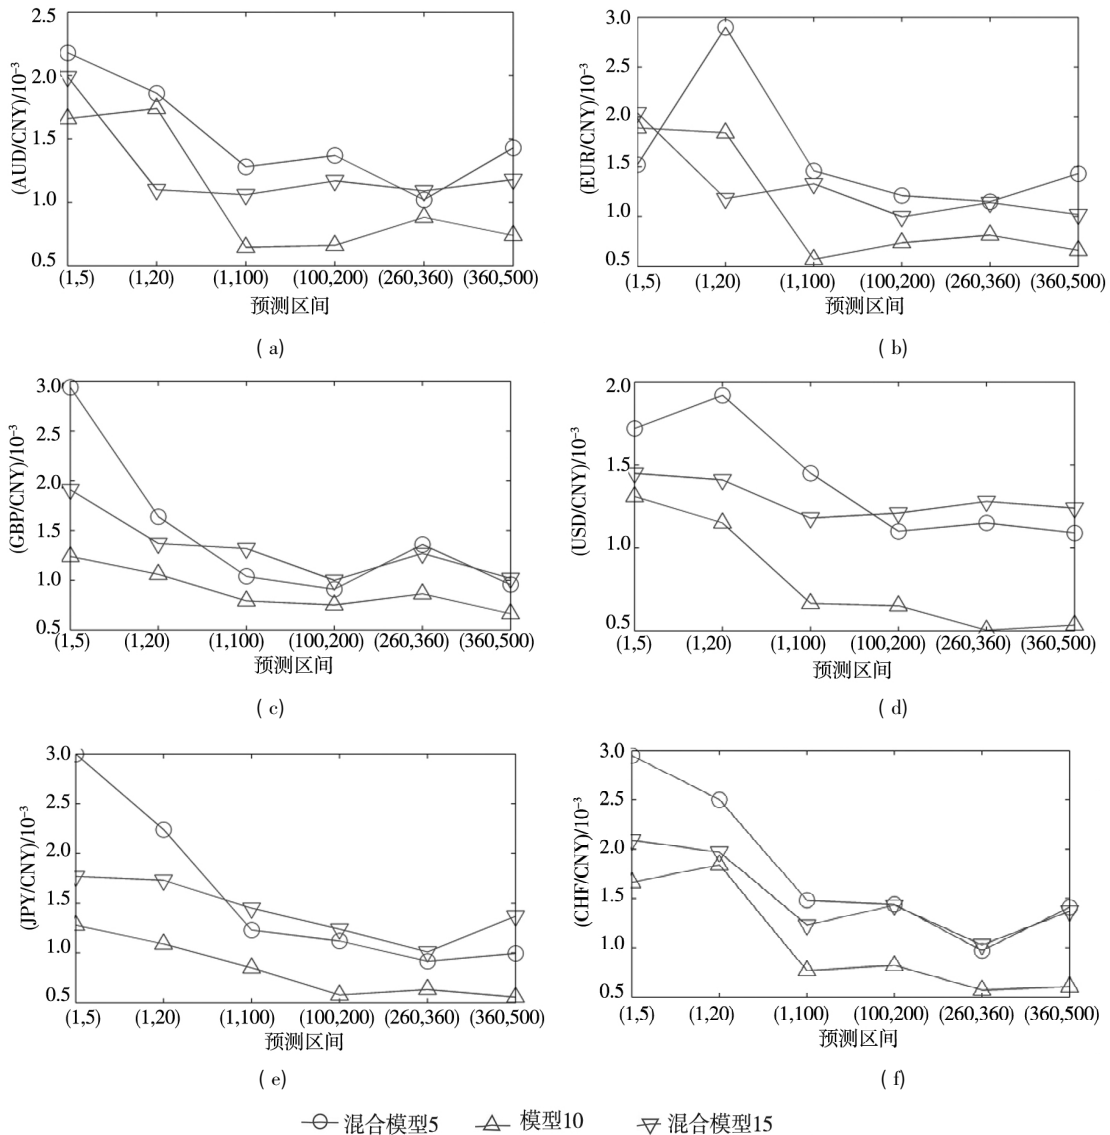


图 6 6 种外汇日已实现波动率的混合模型预测结果

Fig. 6 Predicted results of in one-day realized volatility evaluations of six exchange rates by hybrid volatility model

图中 (a) ~ (f) 分别为澳元、欧元、英镑、美元、日元和瑞士法郎兑人民币的汇率已实现波动率预测结果. 预测采用 RMSE 作为度量, 用 t 期包含 5 个、10 个和 15 个隐含层神经元的 3 种混合模型预测 $t + \tau_1$ 至 $t + \tau_2$ 区间, $(\tau_1, \tau_{t+\tau})$ 如上述表格详述定义.

3 稳健性分析

为保证本文提出模型的可靠性, 延续文献

[28] 的实证分析方法, 采用基于日内高低位幅度波动率 (high-low range-based volatility) 的度量, 对本文提出模型方法进一步检验. 日内高低位幅度波动率的定义为^[27]

$$\sigma_t = \sqrt{\frac{1}{4 \ln 2} (p_t^H - p_t^L)^2} \quad (9)$$

式中 p_t^H 和 p_t^L 分别为日内资产价格的高位和低位. 本文依旧使用 6 种外汇汇率作为实证分析数据, 并计算其日内高低位幅度波动率. 统计学特征如表 4 和表 5 所示.

表 4 日内高低位频幅波动率的统计学特征

Table 4 Statistics of high and low frequency-amplitude volatility in one-day

汇率种类	均值/ 10^{-2}	标准差/ 10^{-2}	偏度	超值峰度
AUD/CNY	4.006 7	2.969 5	2.399 7	12.097
EUR/CNY	3.548 5	2.336 9	1.992 7	5.949 7
GBP/CNY	5.514 4	4.488 2	2.360 6	11.652
JPY/CNY	0.044 095	0.037 546	2.822 6	14.350
USD/CNY	0.890 05	0.890 17	3.685 6	18.583
CHF/CNY	4.157 2	4.549 8	11.752	277.76

表 5 日内高低位频幅波动率滞后检验结果

Table 5 Lag test results of high and low frequency-amplitude volatility in one-day

汇率种类	滞后期						Ljung-Box Q	p
	1	2	3	4	5	6		
AUD/CNY	0.160 22	0.107 87	0.131 28	0.109 24	0.082 075	0.372 59	47.283	0.000 0
EUR/CNY	0.232 86	0.191 93	0.140 63	0.182 10	0.155 86	0.141 30	83.231	0.000 0
GBP/CNY	0.120 17	0.080 904	0.114 09	0.095 524	0.053 256	0.351 73	26.602	2.5×10^{-7}
JPY/CNY	0.269 98	0.188 51	0.214 45	0.174 94	0.131 38	0.340 23	134.19	0.000 0
USD/CNY	0.450 33	0.231 76	0.129 42	0.099 68	0.143 53	0.277 41	258.16	0.000 0
CHF/CNY	0.132 75	0.095 407	0.133 98	0.092 607	0.096 60	0.244 28	32.443	1.0×10^{-8}

用 6 种外汇汇率的日内高低位幅度波动率比较分析混合模型 (10 隐含层神经元)、CGARCH 模型和 EGARCH 模型 3 种模型的预测性能, 如图 7 所示. 混合模型在所有数据和预测区间均取得了稳定和优良的性能. 在个别预测区间, 如澳元和美元兑人民币的 (360, 500) 区间和瑞士法郎对人民币的 (1, 5) 区间, 混合模型和 CGARCH 模型的误差较为接近. 在其余所有数据和预测区间, 混合模型都显著优于 CGARCH 和 EGARCH 模型. 可以

进一步得出结论, 本文的模型在已实现波动率和日内高低位幅度波动率的实证分析中, 都稳定且显著优于其他传统模型.

图中 (a) ~ (f) 分别为澳元、欧元、英镑、美元、日元和瑞士法郎兑人民币的汇率已实现波动率预测结果. 预测采用 RMSE 作为度量, 用 t 期 3 种模型, 混合模型, CGARCH 模型, EGARCH 模型, 预测 $t + \tau_1$ 至 $t + \tau_2$ 区间. $(\tau_1, \tau_{t+\tau})$ 如上述表格详述定义.

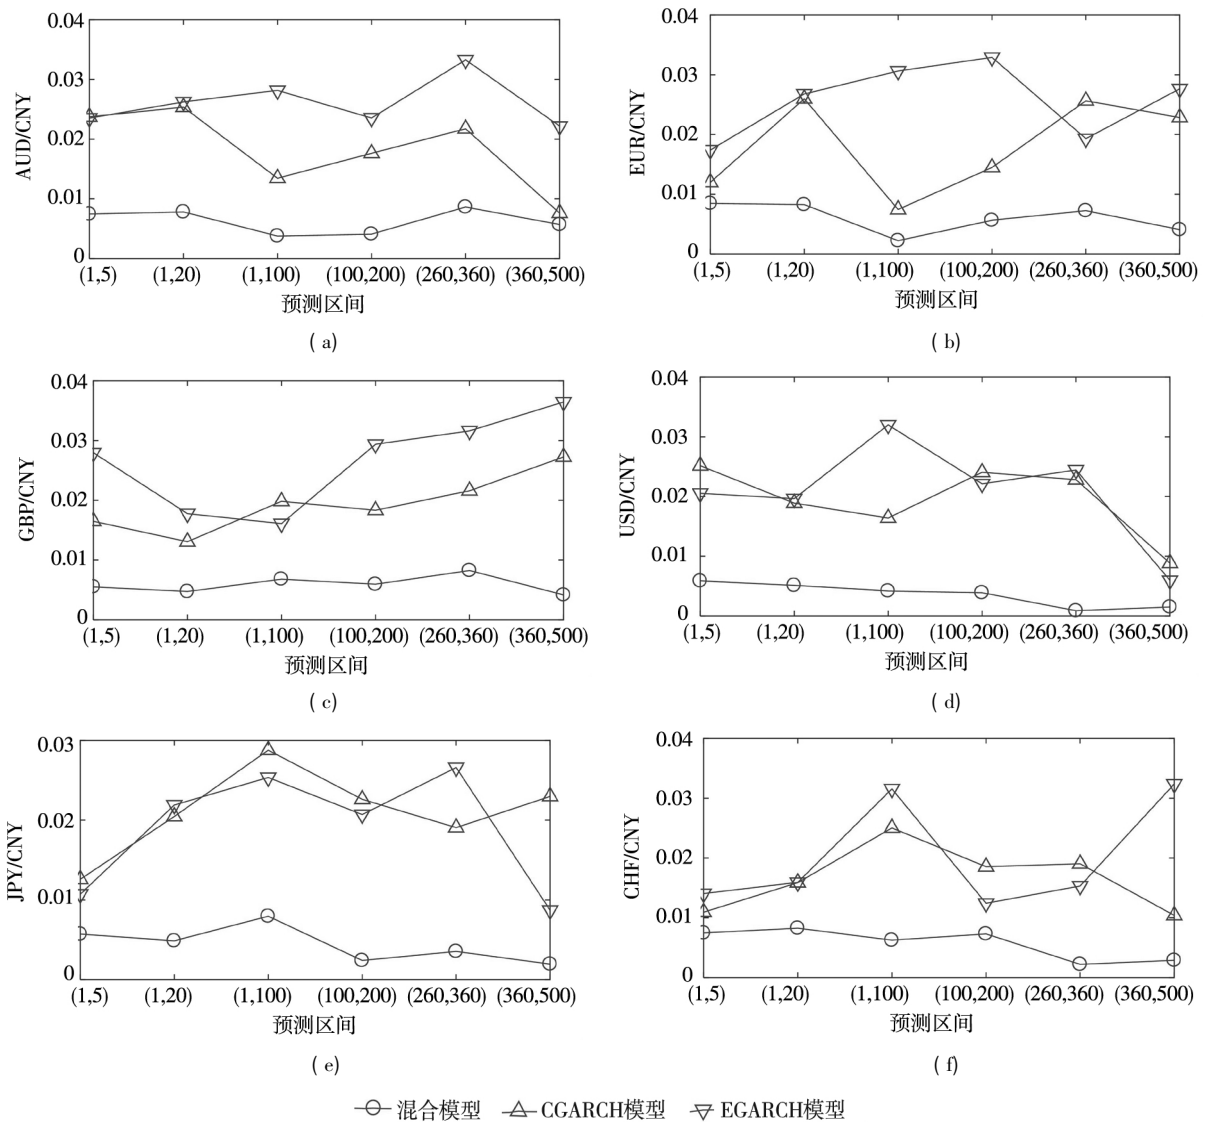


图 7 6 种外汇日内高低位幅度波动率的预测结果

Fig. 7 Predicted results of high and low frequency-amplitude volatility in one-day

4 结束语

本文建立了基于神经网络的简单有效的波动率预测模型,对预测包含长期趋势和短期震荡趋势的波动率有重要意义.模型利用低通 Hodrick-Prescott 滤波器将已实现波动率分解为长期分量和短期分量,使用具有 10 个隐含层神经元的三层四阶滞后自回归神经网络模拟长期分量,简单的自回归过程模拟短期分量,本文将该模型命名为“神经网络增强型双成分波动率模型”.模型在 5 h(d)、20 h(d)、100 h(d)、200 h(d)、360 h(d)、500 h(d) 的预测区间,使用 AUD/CNY, EUR/CNY,

GBP/CNY, JPY/CNY, USD/CNY, CHF/CNY (澳元/人民币,欧元/人民币,英镑/人民币,日元/人民币,美元/人民币,瑞士法郎/人民币) 6 种汇率的高频分组数据,预测 1 h 和 1 d 已实现波动率,并与双成分 GARCH 模型、EGARCH 模型、四阶滞后自回归神经网络模型这 3 个基准模型进行对比,结果显示在绝大多数情况下,本文提出的混合模型样本外预测的精度最高,显著优于这 3 个基准模型.

近 5 年机器学习和数据科学的蓬勃发展大大促进了传统计量经济学的发展,很多研究致力于有效结合计量经济模型和机器学习模型.本文根据不同成分的时间序列特性,使用 HP 滤波器

显式拆分波动率的长期和短期趋势成分,对具有震荡自相关特性的短期分量和呈平滑却具非平稳特性的长期分量,分别使用自回归模型和自回归神经网络模型建模,达到显著优越的预测性能。本文

提出的混合模型设计思路简单,有效结合传统计量模型和机器学习模型,其设计理念为数据科学和计量经济学模型的发展提供了新的研究方向。

参考文献:

- [1] Poon S H, Granger C W. Forecasting volatility in financial markets: A review [J]. *Journal of Economic Literature*, 2003, 41(2): 478 – 539.
- [2] Jiang Y, Ahmed S, Liu X Q. Volatility forecasting in the Chinese commodity futures market with intraday data [J]. *Review of Quantitative Finance and Accounting*, 2017, 48(4): 1 – 51.
- [3] Dimitrios I V. Forecasting realized volatility: HAR against principal components combining, neural network and GARCH [J]. *Research in International Business and Finance*, 2017, 39(B): 824 – 839.
- [4] Engle R F. Autoregressive conditional heteroskedasticity with estimates of the variance of U. K. inflation [J]. *Econometrics*, 1982, 50(4): 987 – 1008.
- [5] Bollerslev T. Modelling the coherence in short-run nominal exchange rates: A multivariate generalized ARCH model [J]. *The Review of Economics and Statistics*, 1990, 72(3): 498 – 505.
- [6] Bollerslev T. Generalized autoregressive conditional heteroscedasticity [J]. *Journal of Econometrics*, 1986, 31(3): 307 – 327.
- [7] Engle R F, Lilien D M, Robins R P. Estimating time varying risk premia in the term structure: The ARCH-M model [J]. *Econometrica*, 1987, 55(2): 391 – 407.
- [8] Nelson D B. Conditional heteroskedasticity in asset returns: A new approach [J]. *Econometrica*, 1991, 59(2): 347 – 370.
- [9] Glosten L, Jagannathan R, Runkle D. On the relation between the expected value and the volatility of the nominal excess return on stocks [J]. *Journal of Finance*, 1993, 48(5): 1779 – 1801.
- [10] Zakoian M. Threshold heteroscedastic models [J]. *Journal of Economic Dynamics and Control*, 1994, 26(18): 931 – 955.
- [11] 文风华, 刘晓群, 唐海如. 基于 LHAR-RV-V 模型的中国股市波动性研究 [J]. *管理科学学报*, 2012, 15(6): 59 – 67.
Wen Fenghua, Liu Xiaoqun, Tang Hairu. Research on China's stock market fluctuations based on LHAR-RV-V [J]. *Journal of Management Sciences in China*, 2012, 15(6): 59 – 67. (in Chinese)
- [12] 陈浪南, 杨科. 中国股市高频波动率的特征、预测模型以及预测精度比较 [J]. *系统工程理论与实践*, 2013, 33(2): 296 – 307.
Chen Langnan, Yang Ke. High-frequency volatility features, forecast models and performance evaluation [J]. *Systems Engineering: Theory & Practice*, 2013, 33(2): 296 – 307. (in Chinese)
- [13] 罗嘉雯, 陈浪南. 基于贝叶斯因子模型金融高频波动率预测研究 [J]. *管理科学学报*, 2017, 20(8): 13 – 26.
Luo Jiawen, Chen Langnan. High-frequency volatility forecast of financial futures based on Bayesian factor model [J]. *Journal of Management Sciences in China*, 2017, 20(8): 13 – 26. (in Chinese)
- [14] Andersen T G, Bollerslev T. Answering the skeptics: Yes, standard volatility models do provide accurate forecasts [J]. *International Economic Review*, 1998, 39(4): 885 – 905.
- [15] Andersen T G, Bollerslev T, Diebold F X, et al. The distribution of realized stock return volatility [J]. *Journal of Financial Economics*, 2001, 61(1): 43 – 76.
- [16] Hansen P R, Huang Z, Shek H. Realized GARCH: A joint model of return and realized measures of volatility [J]. *Journal of Applied Econometrics*, 2012, 27(6): 877 – 906.
- [17] Hansen P R, Huang Z. Exponential GARCH modeling with realized measures of volatility [J]. *Journal of Business & Economic Statistics*, 2016, 34(2): 269 – 287.
- [18] 关璐, 郭名媛. 基于 Realized GARCH 模型的沪深 300 指数波动率研究 [J]. *甘肃科学学报*, 2016, 28(6): 123 – 127.

- Guan Lu , Guo Mingyuan. Shanghai-Shenzhen 300 Index volatility study based on realized GARCH model [J]. *Journal of Gansu Science* , 2016 , 28(6) : 123 - 127. (in Chinese)
- [19] Granger C W. Long memory relationships and the aggregation of dynamic models [J]. *Journal of Econometrics* , 1980 , 14(2) : 227 - 238.
- [20] Granger C W , Joyeux R. An introduction to long-memory time series models and fractional differencing [J]. *Journal of Time Series Analysis* , 1980 , 1(1) : 15 - 29.
- [21] Corsi F. A simple approximate long-memory model of realized volatility [J]. *Journal of Financial Econometrics* , 2009 , 7(2) : 174 - 196.
- [22] 魏 宇. 沪深 300 股指期货的波动率预测模型研究 [J]. *管理科学学报* , 2010 , 13(2) : 66 - 75.
Wei Yu. Volatility forecasting models for CSI 300 index futures [J]. *Journal of Management Sciences in China* , 2010 , 13(2) : 66 - 75. (in Chinese)
- [23] 马 锋, 魏 宇, 黄登仕. 基于跳跃和符号跳跃变差的 HAR-RV 预测模型研究及其 MCS 检验 [J]. *系统管理学报* , 2015 , 24(5) : 700 - 710.
Ma Feng , Wei Yu , Huang Dengshi. The HAR-RV forecasting models with the jump and signed jump variations and its MCS test [J]. *Journal of Systems & Management* , 2015 , 24(5) : 700 - 710. (in Chinese)
- [24] 马 锋, 魏 宇, 黄登仕. 隔夜收益率能提高高频波动率模型的预测能力吗 [J]. *系统工程学报* , 2016 , 31(6) : 783 - 797.
Ma Feng , Wei Yu , Huang Dengshi. Can overnight returns improve the forecasting performance of high-frequency volatility models [J]. *Journal of Systems Engineering* , 2016 , 31(6) : 783 - 797. (in Chinese)
- [25] 马 锋, 魏 宇, 黄登仕. 基于符号收益和跳跃变差的高频波动率模型 [J]. *管理科学学报* , 2017 , 20(10) : 31 - 43.
Ma Feng , Wei Yu , Huang Dengshi. Forecasting the realized volatility based on the signed return and signed jump variation [J]. *Journal of Management Sciences in China* , 2017 , 20(10) : 31 - 43. (in Chinese)
- [26] Engle R F , Lee G J. A permanent and transitory component model of stock return volatility [J/OL]. *Social Science Electronic Publishing* , Oxford University Press , 1999 , 10: 475 - 497.
- [27] Brandt M W , Jones C S. Volatility forecasting with range-based EGARCH models [J]. *Journal of Business & Economic Statistics* , 2006 , 24(4) : 470 - 486.
- [28] Harris R D , Stoja E , Yilmaz F. A cyclical model of exchange rate volatility [J]. *Journal of Banking & Finance* , 2011 , 35(11) : 3055 - 3064.
- [29] Zhai J , Cao Y , Ding X. Data analytic approach for manipulation detection in stock market [J]. *Review of Quantitative Finance and Accounting* , 2018 , 50(3) : 897 - 932.
- [30] Zhai J , Cao Y , Yao Y , et al. Computational intelligent hybrid model for detecting disruptive trading activity [J]. *Decision Support Systems* , 2017 , 93: 26 - 41.
- [31] Boyacioglu M A , Avci D. An adaptive network-based fuzzy inference system (ANFIS) for the prediction of stock market return: The case of the Istanbul stock exchange [J]. *Expert Systems with Applications* , 2010 , 37(12) : 7908 - 7912.
- [32] Svalina I , Galzina V , Lujic R , et al. An adaptive network-based fuzzy inference system (ANFIS) for the forecasting: The case of close price indices [J]. *Expert Systems with Applications* , 2013 , 40(15) : 6055 - 6063.
- [33] Hajizadeh E , Seifi A , Zarandi M F , et al. A hybrid modeling approach for forecasting the volatility of S&P 500 index return [J]. *Expert Systems with Applications* , 2012 , 39(1) : 431 - 436.
- [34] Kristjanpoller W , Fadic A , Minutolo M C. Volatility forecast using hybrid neural network models [J]. *Expert Systems with Applications* , 2014 , 41(5) : 2437 - 2442.
- [35] Kristjanpoller W , Minutolo M C. Forecasting volatility of oil price using an artificial neural network-GARCH model [J]. *Expert Systems with Applications* , 2016 , 65(C) : 233 - 241.
- [36] Kristjanpoller W , Esteban H P. Volatility of main metals forecasted by a hybrid ANN-GARCH model with regressors [J]. *Expert Systems with Applications* , 2017 , 84(C) : 290 - 300.
- [37] Das P P , Bisoi R , Dash P K. Data decomposition based fast reduced kernel extreme learning machine for currency exchange rate forecasting and trend analysis [J]. *Expert Systems with Applications* , 2018 , 96: 427 - 449.

- [38] Stock J H , Watson M W. Dynamic Factor Models , Factor-augmented Vector Autoregressions , and Structural Vector Autoregressions in Macroeconomics [M]. // Taylor J , Uhlig H. Handbook of Macroeconomics , 2 , Amsterdam: North Holland , 2016: 415 – 525.
- [39] Baxter M , King R G. Measuring business cycles approximate band-pass filters for economic time series [J]. Review of Economics and Statistics , 1999 , 81(4) : 575 – 593.
- [40] Ravn M O , Uhlig H. On adjusting the hodrick-prescott filter for the frequency of observations [J]. Review of Economics and Statistics , 2002 , 84(2) : 371 – 375.
- [41] Gorr W L. Research prospective on neural network forecasting [J]. International Journal of Forecasting , 1994 , 10(1) : 1 – 4.
- [42] Zhang G , Qi M. Neural network forecasting for seasonal and trend time series [J]. European Journal of Operational Research , 2005 , 160(2) : 501 – 514.
- [43] Patil S , Tantau H , Salokhe V. Modelling of tropical greenhouse temperature by autoregressive and neural network models [J]. Biosystems Engineering , 2008 , 99(3) : 423 – 431.
- [44] Mustafaraj G , Lowry G , Chen J. Prediction of room temperature and relative humidity by autoregressive linear and nonlinear neural network models for an open office [J]. Energy and Buildings , 2011 , 43(6) : 1452 – 1460.
- [45] Hagan M T , Menhaj M B. Training feedforward networks with the Marquardt algorithm [J]. IEEE Transactions on Neural Networks , 1994 , 5(6) : 989 – 993.

Two-component hybrid volatility models on CNY exchange rates

YAO Yuan¹ , LIU Zhen-qing¹ , ZHAI Jia² , CAO Yi³

1. Institute for Management Science and Engineering , Henan University , Kaifeng 475004 , China;
2. Business School , University of Salford , Salford M5 4WT , UK;
3. Business School , University of Edinburgh , Edinburgh EH1 1LT , UK

Abstract: Volatility forecasting attracts extensive attentions in both finance and computation areas. However , high frequency CNY exchange rates with main stream currencies have not been thoroughly studied due to the lack of the dedicated forecasting model that can capture the dynamics of CNY rates. This paper fills the knowledge gap by , firstly , proposing a two-component hybrid volatility model based on a neural network , which is composed of a low-pass filter , the machine-learning algorithm , and the traditional autoregressive model , and secondly , studying the forecasting performance thoroughly using the one-hour and one-day realized volatility constructed from high frequency rates of six major rates: GBP/CNY , USD/CNY , AUD/CNY , EUR/CNY , JPY/CNY , and CHF/CNY. The predicting results are compared with component GARCH , EGARCH and neural network only models. The experimental evaluations show that our proposed model outperforms the traditional models in CNY forecasting volatility significantly and consistently across all forecasting horizons.

Key words: realized volatility; exchange rate; ANN; C-GARCH; HP filter