

# 基于随机森林算法和模糊信息粒化的 汇率预测组合模型研究<sup>①</sup>

熊景华<sup>1,2</sup> 茹 璟<sup>1</sup>

(1. 华南理工大学经济与金融学院; 2. 武汉大学水利水电学院)

**研究目标:** 本文致力于利用智能算法, 提升汇率预测精度, 为跨境资本流动和汇率风险防范提供参考依据。 **研究方法:** 引入机器学习前沿领域的随机森林算法 RF, 结合模糊信息粒化 FIG, 利用参数和非参数模型构建具有更精准汇率预测能力的组合模型。 **研究发现:** 基于 RF 和 FIG 构建的组合模型其汇率预测精度分别优于常用的 ARIMA、GARCH、SVR 单一模型 15.5%、16.7% 和 36.6%; 模糊信息粒化可以实现汇率的变尺度的区间预测, 且区间均值比点预测更加精准; 模糊粒化窗口为季度时模型表现最好, 模型误差随窗口宽度先增后减。 **研究创新:** 一是利用随机森林算法合理分配权重将三种单一模型导入汇率预测组合模型, 经过 PCA 降维和 FIG 处理, 增强汇率预测精度。二是利用模糊信息粒化将汇率波动预测从点预测转化为区间预测, 并可通过修改时间窗变换预测的时间周期。 **研究价值:** 随着人民币国际化和汇率市场化不断深化, 汇率双向波动加强, 精准预测汇率对宏观决策和微观主体都具有重要意义。

**关键词** 汇率预测 随机森林算法 模糊信息粒化 组合模型

**中图分类号** F821.6 **文献标识码** A

## 引言

面临新冠肺炎疫情严重冲击和国际经济形势复杂多变, 国际金融市场不确定性因素增多。汇率在国际经济联系中发挥着重要作用, 随着中国资本市场双向开放的继续推进, 跨境资本流动规模逐步上升。为了防范汇率过大波动带来的跨境金融风险, 世界各大经济体对汇率波动一直给予高度重视, 纷纷制定宏观经济政策来稳定汇率; 参与跨境贸易和投融资的企业和金融机构也大力开展金融科技来预测汇率, 运用各种外汇避险工具和手段, 以降低汇率波动风险造成的损失; 对于个人投资者, “炒汇”也被当作一种伴随高风险的投资, 投资者可以通过预测汇率波动来套利。可见汇率预测在宏观经济政策研究及制定、跨国经营的企业管理和个人外汇投资中都发挥着重要作用。汇率预测是汇率风险管理的首要前提和重要基础, 精准的汇率预测帮助确定汇率波动方向和波幅大小, 测定风险强弱, 是中央银行加强金融监管以及经济主体规避外汇风险的重要内容。因此, 汇率预测模型成为国际金融领域的研

<sup>①</sup> 本文获得国家社会科学基金重大项目“粤港澳大湾区跨境资本流动与金融风险防范研究”(19ZDA093) 的资助。茹璟为本文通讯作者。

究热点和关注焦点问题。

浮动汇率制度下，汇率波动的发生、形成和演变具有复杂多变的非线性特征，实现对汇率的精准预测愈加困难。随着2005年我国央行开始实行汇率市场化改革，构建有管理的浮动汇率制度，人民币汇率市场化程度不断提升，其双向波动的不确定性与日俱增。2019年8月，人民币对美元汇率创造了最近11年的新低点，“人民币破7”被各大媒体当作头条新闻争相报道，汇率波动引发社会广泛关注。截至2020年7月末，我国持有3.15万亿美元外汇储备，随着中美贸易摩擦不断升温，跨境资本流动风险陡增。

通过文献梳理，目前学界主流汇率预测方法包括基本分析法和技术分析法两大类，前者的研究多基于传统汇率决定理论构建经济基本面模型，后者的研究根据建模原理由参数方法与非参数方法组成。基本分析法根据汇率决定理论，如购买力平价理论和利率平价理论等，建立宏观的长期模型（Zorzi等，2016；Ismailov和Rossi，2018）。国内外学者对各种利率决定理论的实证研究表明，宏观经济结构模型在预测一年之内的汇率方面基本是无效的（Frankel和Rose，1995），对于解释浮动汇率表现较差（Cheung等，2005；Bhargava等，2011），其短期预测表现劣于技术分析法，而在长期预测中更占优势（徐立本和罗士勋，2005；邓贵川和李艳丽，2016）。

技术分析法基于大量历史数据在预测中短期汇率变动方面得到推广，其经历了从线性参数模型到非线性参数模型再向非参数模型演进，从单一模型到组合模型的优化。基于强大的市场理论，即“价格反映所有信息”，当各国的汇率转向浮动汇率制时，参数模型得到了迅速发展。参数方法仅基于汇率的历史数据对模型参数进行估计，主要包括单整自回归滑动平均（ARIMA）模型（Box等，1976）、随机游走模型（Engle，1982）、自回归条件异方差模型（ARCH）（Meese和Rogoff，1983）以及在其基础上改进的广义自回归条件异方差模型（GARCH）（Bollerslev，1986）等。Rout等（2014）发现利用线性参数模型ARIMA模型对经过差分处理后的汇率序列进行拟合能够消除数据的冗余现象，较好模拟汇率波动。Tseng等（2001）和Khashci等（2009）都认为经过模糊化的ARIMA模型在预测未来时间序列的表现上优于普通的ARIMA模型，并且表现更加稳健。国内学者也发现ARIMA模型对人民币汇率具有较强预测能力（魏巍贤，2000；张忠杰，2005）。但是，ARIMA模型作为线性参数模型，要求汇率数据是完全平稳且呈线性变化，无法解决非线性汇率变化的系统问题（Panda和Narasimhan，2003；Santos等，2007；谢赤等，2008）。

非线性的参数模型随后得到学者们的重视。Aguilar和Nydahl（2000）发现GARCH模型对于瑞典克朗中短期预测性能优于基础分析法。Baruník等（2016）进一步提出特别是对于具有跳跃效应的高频时间序列，GARCH模型的表现优于ARIMA模型。惠晓峰等（2003）建立GARCH模型对2003年汇改后的人民币汇率变化进行实证分析，汇率预测结果较好。但是，He和Wan（2009）发现尽管GARCH模型可以较好解释汇率波动的非线性特征，但其要求数据满足正态分布的前提，模式对称性使其难以识别条件方差不对称的变化，且对经济变量的杠杆效应无能为力。Anastasakis和Mort（2009）认为GARCH模型与ARIMA模型类似，也要求金融数据平稳并具有ARCH效应，而一阶差分等平稳后操作将使汇率时序信号削弱，故该模型对较复杂的非线性波动解释能力较弱，难以保证模型精确度。

鉴于汇率波动的复杂性和参数模型对原始数据提出的高要求等劣势，许多学者开始使用非参数方法对汇率进行预测。机器学习领域的智能算法对大数据预测具有明显优势，近年越

越来越多的智能算法在汇率预测中发挥重要作用。人工神经网络（ANN）首先被应用于预测汇率变化（Kuan 和 Liu, 1995），不久后支持向量机和遗传算法也被运用到汇率预测领域（Arifovic, 1996；Cao, 2003），还有奇异谱分析（张一和惠晓峰, 2012；Abreu 等, 2019）和贝叶斯分类器（毕玉江和王双成, 2016）等。由 Vapnik (1998) 提出的支持向量回归机（SVR）因能求得全局最优解、对数据量要求低且不需要数据满足特定分布、泛化能力强等优点。SVR 被广泛应用于汇率预测研究，以监测结构化的参数模型难以拟合的复杂非线性波动（Pai 等, 2006；Yuan, 2013）。陈诗一（2007）利用 SVR 模型预测了四种货币的汇率并与 MLE 和 ANN 的预测结果相比较，发现 SVR 模型预测效果最好。但是，Xie 等（2015）认为尽管以 SVR 为代表的非参数模型在预测复杂的高频汇率时序表现优于 ARIMA 和 GARCH 模型的参数模型，其在拟合汇率的线性变化时表现却不如传统的 ARIMA 模型。Chen 等（2010）也发现对于预测汇率正态性大样本情况下的非线性变化表现也劣于 GARCH 模型。但是，对于回归性能稳健的非参数模型，比如人工神经网络，其运算复杂、求解速度慢等缺陷使其实用性降低，且以单纯统计算法为基础的汇率预测模型不能体现经济基本面。

汇率波动作为包含线性与非线性过程的复杂系统，依靠任何单一模型很难完全解释其波动过程（Maia 等, 2008），故学者通过将多个不同类型的模型结合，构建汇率预测组合模型，将汇率波动分解为线性波动与非线性波动两部分，通过不同类别的模型分别对每一部分进行建模预测，将结果叠加作为组合模型结果（He 等, 2010），利用各自的优势减小预测汇率的误差（Hajizadeh 等, 2019）。Sermpinis 等（2012）将 Psi Sigma 神经网络与 Kalman 滤波、最小二乘估计、贝叶斯平均值、Granger-Ramanathan 回归和 LASSO 回归相结合，发现组合模型的最终结果优于现所有单一模型。Sermpinis 等（2015）又进一步发现基于遗传算法参数寻优的支持向量回归机优于人工神经网络。国内的学者也得到了类似结论（傅魁和郭志颖, 2018）。

目前，基于组合模型预测人民币汇率变化的研究较少，且大部分仅通过使用智能算法或非线性模型对线性模型预测的残差项进行拟合，然后叠加两者的预测结果作为最终结果，这种方法带来的二次误差可能使模型精度不增反降；另外一种组合方式对不同类别的模型预测值加权平均作为最终预测结果（Makridakis 和 Winkler, 1983），但其很难确定单一模型的权重，具有较大不确定性，且难以体现经济基本面。除此之外，现有基于智能算法的组合模型预测周期固定，难以满足不同情境下的预测需要，同时实现短、中、长期实时预测；并且组合模型预测结果为定值，实际意义有限，忽略了汇率预测的波动性和时变性。李欣珏和牛霖琳（2019）认为模型的预测能力不仅要看模型设定的准确性，还要关注参数的结构性变化和时变特征。

## 一、研究方法优化

### 1. 随机森林算法（Random Forest, RF）

随机森林算法是机器学习领域一种比较新的集成算法。Breiman (2001) 提出的基于分类树的 RF 集成算法，作为原 Bagging 算法的优化，RF 使用 Bagging 算法通过监测变量残差平方和或回归平方和的边际减小量来评价解释变量的相对权重，能很好地排除异常值的影响，具有更好的预测精度（Kampichler 等, 2010）。

与传统预测模型相比，RF 具有以下四个优点：第一，对数据集适应能力强，不需要数

据满足事先设定的假设条件或特定函数形式，对多元共线性不敏感，对缺失数据和非平衡数据比较稳健。第二，建模简单高效，泛化能力强，利用决策树多路径并行的优点迅速捕捉拐点。随着回归树的棵数增加，RF模型误差能得到整体上的缩减。对比SVR或者人工神经网络，其率定参数较少，仅需指定回归树的棵数与每个分叉节点采样的特征数，训练过程更简单快速。第三，能处理高维数据集，RF能够避免机器学习的通病，不容易产生过拟合和欠拟合的问题。第四，RF能够得到各个变量的权重，评估变量在模型中所起的重要性作用。已有学者将随机森林算法运用到金融领域，比如马晓君等（2019）将RF运用到上市公司的信用评级中。总而言之，RF模型对于高频的人民币汇率序列可以获得良好的效果，适用于处理人民币汇率波动的复杂问题，具有良好的先进性。

与单一模型不同，RF模型输出结果是多棵决策树的众数或平均值（当处理分类问题时，为众数；当处理回归问题时，为均值），根据Winham（2012）等人的研究，当RF的回归树棵数趋于无穷大时，满足：

$$E_{X,Y}[Y - av_j h(X, \theta_j)]^2 = E_{X,Y}[Y - E_\theta h(X, \theta_j)]^2 \quad (1)$$

其中 $av_j$ 表示某棵树统计指标的平均值， $j$ 为树的棵数，当其趋于无穷大时，即可用 $Y = av_j h(X, \theta_j)$ 代替RF的回归函数 $E_\theta h(X, \theta_j)$ ，此时每棵回归树的泛化误差可用 $PE^*$ 表示，其数学公式表达如下：

$$PE^*(tree) = E_\theta E_{X,Y}[Y - h(X, \theta_j)]^2 \quad (2)$$

若对任意 $\theta$ 都有 $E_Y = E_X h(X, \theta)$ ，满足：

$$PE^* \leq \bar{\rho} PE^*(tree) \quad (3)$$

本文使用RF作为人民币汇率预测组合模型的基础，基于基尼指数将ARIMA、GARCH和SVR模型有机联结，依据大量决策树的结果给出最精准的预测值，并且在数据预处理阶段，使用PCA算法进行降维可以过滤不同模型拟合值重叠部分对预测结果的干扰。

RF模型的建模过程可简要叙述如下：

(1) 在数据集的若干个样本中，利用Bootstrap算法重复进行有放回的随机采样，抽取 $x$ 个样本作为训练样本，并相应地构建 $x$ 棵回归树，此时未被抽样选中的样本作为测试样本评价训练结果的优劣，它们在统计学上被称为袋外(Out of Bag, OOB)数据。

(2) 对于每一棵回归树，在其分枝节点处随机从 $k$ 个特征变量中选取 $m$ 个，然后根据最小信息化原则依据各个子节点的熵增或基尼不纯度平均减小值确定最优分类特征，并进行下一个子节点的分枝过程，形成没有约束的回归树模型。

(3) 依据步骤(2)中叙述的规则，每棵回归树都可以自由生长，直到达到人为设定的回归树棵数的阈值上限 $n$ 。本研究中对 $m$ 和 $n$ 采用循环遍历法进行识别，在某一范围内寻找使得RF整体误差最小的参数组合( $m, n$ )。

(4) 模型构建完成后，RF对OOB数据进行无偏估计计算MSE来评判模型的拟合优度(Sun等，2016；Ibrahim和Khatib，2017)模型通过计算回归树均方误差的平均值以及可决系数来评判RF本身的性能，而每棵树的均方误差(MSE)即通过(1)中的OOB数据计算，其公式如下：

$$MSE_{OOB} = \frac{\sum_{i=1}^o (y_i - \hat{y}_i)^2}{o} \quad (4)$$

其中  $MSE_{OOB}$  是模型拟合的 MSE 值,  $\hat{y}_i$  和  $y_i$  分别为第  $i$  个 ( $i=1, 2, \dots, o$ ) RF 模型预测值和真实值,  $o$  为袋外样本容量。

除了作为单一汇率模型时可以取得良好效果, RF 还能构建组合模型实现对人民币汇率的预测, 对比其他组合模型的简单相加或加权平均, 基于每个分枝节点处的 OOB 数据, RF 模型计算基尼系数平均减小值 (Mean Decrease Gini, MDG) 将输入变量按输出因子的重要性降序排列 (Behnamian 等, 2017), 并通过各个评价指标对于因变量的权重分析实现汇率预测单一模型的有效组合, 得到预测精度更高的组合模型。基于每个分枝节点处的 OOB 数据, RF 通过基尼系数平均减小值 (Mean Decrease Gini, MDG) 将输入变量按对输出因子的重要性降序排列 (Behnamian 等, 2017), RF 对 OOB 数据进行无偏估计来评判模型的拟合优度 (Sun 等, 2016; Ibrahim 和 Khatib, 2017), MDG 表示所有 CART 的树节点分裂前后每个特征 Gini 指数的平均下降值, 由于其简单性以及快速计算分类和回归的能力, 被认为是进行权重分析强大而创新的指数 (Han 等, 2016; Nembrini 等, 2018)。基尼指数 (Gini Index) 作为衡量特征相关性的指标, 使黑箱算法内的参数识别过程可视化 (Menze 等, 2009), 基于基尼指数, 父节点通过分裂形成两个子节点并且两代节点之间达到平衡 (Chen 等, 2015), 变量的异质性和相关性可以得到测定。

假设每棵回归树生长  $D$  个树节点, 其基尼指数计算如下 (Chen 等, 2015):

$$Gini(i) = 1 - \sum_{j=1}^n \left[ \frac{X(i,j)}{\sum_{j=1}^n X(i,j)} \right]^2, i \in d \quad (5)$$

其中,  $X(i, j)$  是指第  $j$  个宏观经济变量的第  $i$  个指标,  $d$  为回归树的节点序号, ( $d=1, 2, \dots, D$ ), 当节点  $d$  分裂生成两个子节点后, 两个子节点处的基尼指数将趋于最小化, 并作为节点  $d$  处基尼指数的最终值:

$$|Gini(d), v| = \min\{Gini(i) | i \in d\} \quad (6)$$

当节点  $d$  处分裂成两个子节点后, 其子节点的基尼指数之和较之父节点下降, 下降的绝对值计算如下:

$$\Delta Gini(d) = Gini(d) - \frac{n_l}{n} \cdot Gini(d_l) - \frac{n_r}{n} \cdot Gini(d_r) \quad (7)$$

其中,  $Gini(d_l)$  是左子节点的基尼指数,  $Gini(d_r)$  是右子节点的基尼指数,  $n_l$  和  $n_r$  分别是左右节点包含的样本量。回归树中指定变量的权重表示为所有节点  $\Delta Gini(d)$  的总和, 对于 RF, 其表示为 MDG, 即所有回归树  $\Delta Gini(d)$  的平均值。MDG 指标已经被广泛应用于 RF 中的变量选择和权重分析 (Menze 等, 2009; Boulesteix 等, 2012; Han 等, 2016; 吴孝情等, 2017)。

## 2. 模糊信息粒化 (Fuzzy Information Granularity, FIG)

20 世纪 60 年代, Zadeh 教授首次提出了模糊集合论, 并于 1979 年提出了信息粒的概念。信息粒 (Information Granularity, IG) 是针对研究对象的不可区分性、功能相近性、相似性、函数性等相似特征划分的数据集合, 信息粒化过程则是将整个数据集合分解成若干小集合进行分析, 并将每个小集合作为一个信息粒, 且每个信息粒可以细分为更小的信息粒 (Zadeh, 1979)。粒化计算是信息处理的一个新分支, 隶属于软计算科学。到 20 世纪 90 年代, 信息粒化逐渐受到人们的关注。信息粒化方法按照信息粒的种类包括非模糊制粒

(CIG) 和模糊制粒 (FIG) 方法。在方法论理论中, 非模糊制粒法占有非常重要的位置, 但对于大部分缺少先验信息的研究, 模糊信息粒化能够发挥更大作用, 目前主要有三种经典模型, 即模糊信息造粒模型, 粗糙集信息造粒模型和熵空间信息模型, 本文使用模糊信息造粒模型对人民币汇率进行处理。

模糊信息造粒理论也来自 Zadeh (1979), 并在各个领域都得到了大力推广。在处理时间序列方面, 学者对传统的时间序列进行模糊化预处理将其转化为信息粒从而进行信息粒尺度的研究 (李晓新和张屹山, 2019; 孙轶轩等, 2014)。模糊粒化过程主要包括时序窗口划分和模糊粒化两个部分, 前者是指通过指定宽度的时间窗将其分割为若干个子序列, 而后者是指对每一个分割得到的子序列模糊化生成信息粒子。模糊粒化是非常重要的部分, 它在指定的操作窗口上建立合适的模糊集, 该模糊集可以替换原始窗口的数据, 也可以完全表达信息。式 (8) 和式 (9) 从数学角度说明了 FIG 算法的实现过程: 对时间序列  $x$  给定模糊化窗口后, 即可在原时间序列  $x$  上创建模糊粒子  $P$ :

$$g \triangleq x \in G \quad (8)$$

$$P = A(x) \quad (9)$$

其中  $A$  是隶属函数,  $g$  是信息粒。模糊化本质上就是确定性函数  $A$  的表达。以下是主流信息粒类型及其隶属函数:

$$\begin{aligned} \text{三角函数集: } A(x, a, m, b) &= \begin{cases} 0 & x < a \\ \frac{x-a}{m-a} & a \leq x \leq m \\ \frac{b-x}{b-m} & m < x \leq b \\ 0 & x > b \end{cases} \\ \text{梯形模糊集: } A(x, a, m, n, b) &= \begin{cases} 0 & x < a \\ \frac{x-a}{m-a} & a \leq x \leq m \\ 1 & m \leq x \leq n \\ \frac{b-x}{b-n} & n < x < b \\ 0 & x > b \end{cases} \\ \text{非对称抛物型模糊集: } A(x, a, m, b) &= \begin{cases} 1 - \left(\frac{m-x}{m-a}\right)^2 & a \leq x \leq m \\ 1 - \left(\frac{m-x}{m-b}\right)^2 & m < x \leq b \\ 0 & x \text{ 为其他数值} \end{cases} \end{aligned}$$

### 3. 预测对比模型

(1) 单整自回归滑动平均模型 (ARIMA)。ARIMA 模型对经过差分或对数化后的原始时间序列, 实现拟合和预测 (Box 等, 1976), 要求时间序列平稳, 然而大多数金融时间序列具有趋势性、周期性或存在突变点, 很难满足平稳条件。对于汇率时间序列, 多数学者通常采用先取对数后取阶差的方法得到对数差的汇率序列, 适当的平稳处理可以获得有效信息, 例如差分后的增长率和取对数后的弹性系数, 为了提取序列的确定性信息, 有的学者直

接采用一阶或二阶差分运算来稳定化处理（李志超和刘升，2019；刘进和郭进超，2019）。

本文使用  $d$  阶差分来平滑非平稳序列，获得平稳序列后需要对序列进行白噪声检验以证明其含有研究所需的有效信息。其建模过程包括自回归过程 AR (p)、移动平均过程 MA (q)、自回归移动平均过程 ARMA (p, q) 和 ARIMA (p, d, q) 模型。模型基本公式：

$$\Delta^d y_t = \theta_0 + \sum_{i=1}^p \phi_i \Delta^d y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} \quad (10)$$

其中， $y_t$  是原始序列， $\Delta^d y_{t-i}$  是  $d$  阶差分后得到的平稳序列， $\varepsilon_{t-j}$  是白噪声序列， $\phi_i$  ( $i = 1, 2, \dots, p$ ) 和  $\theta_j$  ( $j = 1, 2, \dots, q$ ) 为模型参数， $p$  和  $q$  为其阶数。

(2) 广义自回归异方差模型 (GARCH)。GARCH 线性扩展了 ARCH 族模型中对异方差的约束，通过使条件方差作为前期序列误差与滞后项条件方差的函数来反映波动率聚集效应 (Bollerslev, 1986)。作为更成熟的计量经济学模型，GARCH 通常被研究者与时间序列结合分析以应用于波动特征的预测中，GARCH 模型考虑了金融序列的重要特征：前沿峰度和波动聚类，通过对异方差的成功描述，GARCH 能够准确地预测波动趋势和方差，因此其在金融风险评估领域得到了广泛的应用，特别是证券研究和汇率预测方面（郑振龙和黄慧舟，2010；龚锐等，2005）。GARCH 模型本质上是一种使用过去的波动来解释将来的波动的机制，从计量角度上说，这是一种时间序列建模方法，即通过使用前期时序变化及其方差来预测后期时序波动。GARCH 模型的数学表达式如下：

$$y_t = x_t \beta + \varepsilon_t \quad t = 1, 2, \dots, N \quad (11)$$

$$\varepsilon_t | \Phi_t \sim N(0, h_t) \quad (12)$$

$$\begin{aligned} h_t &= \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j h_{t-j} \\ &= \alpha_0 + A(L) \varepsilon_t^2 + B(L) h_t \end{aligned}$$

$$p > 0, q \geq 0, \alpha_0 > 0, \alpha_i \geq 0 \quad (i = 1, 2, \dots, p), \beta_i \geq 0 \quad (i = 1, 2, \dots, q) \quad (13)$$

其中， $x_t$  和  $y_t$  分别是方程的自变量和因变量， $x_t$  为  $y_t$  衍生变量或滞后项， $\beta$  是  $x_t$  和  $y_t$  的相关系数，残差  $\varepsilon_t$  在  $t$  时间内信息集可体现为  $\varepsilon_t | \Phi_t \sim N(0, h_t)$ ， $h_t$  为条件方差， $\alpha_0$  是常数项， $\alpha_i$  和  $\beta_i$  为过去误差和滞后条件方差的系数。

(3) 支持向量回归机 (SVR)。SVR 模型对于线性回归问题，其实质是寻找过各点的直线  $L$  的方程  $y = kx + b$ ， $x_i \in R$  并分布在二维空间上，这两类数据点可以被分类线  $L$  完全分开，数据点  $(x_i, y_i)$  为训练样本，引入变量  $\epsilon$ ，对于每个训练样本，依次令  $y_{i1} = y_i + \epsilon$ ， $y_{i2} = y_i - \epsilon$ ，则  $(x_i, y_{i1})$ 、 $(x_i, y_{i2})$  分别构成新点集作为分类问题的训练集：

$$\{[(x_i, y_i + \epsilon), 1], [(x_i, y_i - \epsilon), -1], i = 1, 2, \dots, k\} \quad (14)$$

通过将线性过程推广到高维空间  $R^n$  内即可将不可分问题转化为可分问题，引入松弛变量、惩罚因子和核函数进行参数识别过程，即可训练 SVR 模型。实际上无论在二维空间或高维空间，都无法完全分离不同类型样本点。为了解决这一问题，通过引入参数：松弛变量  $\xi_i$  ( $\geq 0$ ) 和惩罚因子  $C$  ( $> 0$ )，前者可以适当放宽约束条件，后者则作为分类间隔和松弛变量的权重，从而在高维问题中满足不同的预测需要（林升梁和刘志，2007）。

对于样本线性不可分时，有必要则引入适当的变换将平面上的点集通过某种映射关系

$(x' = \Phi(x))$  投影到高维空间中，转化成可分类问题，此时最优化问题的目标函数为：

$$\min_{\alpha} \frac{1}{2} \sum_{i=1}^k \sum_{j=1}^k y_i y_j [\Phi(x_i) \cdot \Phi(x_j)] \alpha_i \alpha_j - \sum_{i=1}^k \alpha_i \quad (15)$$

分类函数为：

$$g(x) = \operatorname{sgn} \left\{ \sum_{i=1}^k \alpha_i^* y_i [\Phi(x_i) \cdot \Phi(x)] + b^* \right\} \quad (16)$$

$\Phi(x)$  以  $\Phi(x) \cdot \Phi(x')$  的形式出现，令核函数  $K(x, x') = \Phi(x) \cdot \Phi(x')$ ，主流的核函数如下所示（奉国和，2011）：

线性核函数： $K(x, x') = x_i^T \cdot x_j$

高斯核函数： $K(x, x') = \frac{1}{\sigma \sqrt{2\pi}} \exp \left( -\frac{1}{2} \cdot \left( \frac{x - \mu}{\sigma} \right)^2 \right)$

RBF核函数： $K(x, x') = \exp(-\gamma \|x_i - x_j\|^2)$

## 二、数据来源及预处理

### 1. 数据来源

本文选取人民币对美元汇率中间价的月度数据进行研究，数据时段为2010年6月至2019年6月，数据来自中国外汇交易中心。根据购买力平价理论、利率平价理论、国际收支理论等汇率决定理论，本文选择的训练集指标包括中美两国的CPI、M2（亿元/亿美元）、利率、进出口贸易差额（亿美元/百万美元）、GDP（亿元/十亿美元）、国家外汇储备（亿美元/百万美元），还加入了代表心理预期的消费者信心指数、单一模型拟合值和上个月度的人民币汇率值，时间跨度与汇率数据相同。

中国的CPI、M2、进出口贸易差额、利率、消费者信心指数等月度数据和GDP季度数据均来自CEIC中国经济数据库；中国的国家外汇储备月度数据来于中国国家外汇管理局；美国的经济指标除GDP为季度数据外，其余均为月度数据，且所有数据均来自美国联邦储备银行数据库。所有按月发布的指标都采用月度值，按季发布的指标（GDP）按照均匀增长的假设插值补充为月度值。

### 2. 数据预处理

中国和美国政府发布的GDP数据时间尺度包括季度与年度，需要对GDP数据进行尺度变换。假定当季每月均匀增长，即满足：

$$GDP_q = GDP_{m1} + GDP_{m2} + GDP_{m3} \quad (17)$$

$$GDP_{m2} = GDP_{m1} \cdot (1 + \alpha) \quad (18)$$

$$GDP_{m3} = GDP_{m2} \cdot (1 + \alpha) \quad (19)$$

其中， $GDP_q$  为当季GDP， $GDP_{m1}$ 、 $GDP_{m2}$ 、 $GDP_{m3}$  分别是季度内各月GDP， $\alpha$  为当季GDP环比增长率。求解该方程组可以得到每个月的GDP。

所有的数据均经过归一化与主成分分析（PCA）降维处理，之后再进行后续模型的调试与训练。为了消除指标体系中各个经济变量之间巨大的量纲差异，本文采取以下公式对所有数据进行归一化，将其值缩放至  $[0, 1]$  范围内，进而进行分析：

$$x^* = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (20)$$

其中  $x_{max}$  为某指标的序列最大值,  $x_{min}$  是该指标序列最小值,  $x$  和  $x^*$  分别是该指标序列归一化前和归一化后的值。

为了减少高维度数据给建模分析带来的影响, 本文对评价指标体系运用主成分分析进行降维, 缩减解释变量的维度, 从而提高预测精度, 公式如下所示:

$$\left\{ \begin{array}{l} f_1 = b_{11}x_1 + b_{12}x_2 + b_{13}x_3 + \cdots + b_{1n}x_n \\ \cdots \\ f_m = b_{m1}x_1 + b_{m2}x_2 + b_{m3}x_3 + \cdots + b_{mn}x_n \end{array} \right\} \quad (21)$$

其中  $f_1$ 、 $f_2$ 、 $\cdots$ 、 $f_m$  分别是  $x_i$  ( $i=1, 2, \cdots, n$ ) 的第一主成分、第二主成分、 $\cdots$ 、第  $m$  主成分。

### 三、参数与非参数模型效果评估

本文需将 ARIMA 模型、GARCH 模型、SVR 模型对 2010 年 6 月至 2019 年 6 月人民币对美元汇率的拟合值加入到原有评价指标体系中, 通过增加与人民币汇率波动强相关的指标有效提高对人民币汇率预测的精度, 故本文首先对三个单一模型分别进行预测效果评估。

#### 1. ARIMA 模型汇率预测效果

通过对汇率时序的统计性结果发现, 2010 年 6 月到 2019 年 6 月人民币对美元汇率均值是 6.4600, 标准差为 0.2609, 表面整体波动不大, 偏度 0.3209, 该序列非对称、非正态、右偏且具有尖峰, 峰度 1.8285, 其分布相对正态分布更陡, 结合 J-B 统计量和 P 值, 可证明该序列不服从正态分布。由于所研究区段内的人民币汇率是不平稳的, 需要对其进行取对数或者差分处理后进行分析, 将时间序列数据在 Eviews8.0 软件中构建 ARIMA 模型, 具体步骤如下:

(1) 通过对人民币汇率序列进行对数差分, 发现其 ADF 检验统计量为 -7.4399, 且表现为平稳序列, 在此基础上进行的白噪声检验, 发现在 5% 置信度下, 各阶滞后阶数的 P 值均小于 0.05, 可认为通过白噪声检验, 故对其建立 ARIMA 模型。

(2) 在 ARIMA 模型的一阶差分序列的相关图中, 自相关系数  $k=1$  后收敛于 0, 故  $q$  值取 1; 而偏相关系数在  $k=1, 2, 3, 4$  时均在临界值附近波动, 之后迅速收敛于 0, 故  $p$  值分别取 1、2、3、4; 差分项  $d$  值取 1。此时, 我们根据信息最小化原则, 分别取 AIC、HQC 和 SIC 值最小时的模型作为本研究的预测模型, 即 ARIMA (1, 1, 1) 模型。

(3) 对 ARIMA (1, 1, 1) 待估计参数 AR (1)、MA (1) 和 C 进行统计学检验, 发现模型各项基本通过 99% 显著性水平, 模型  $R^2$  为 0.3441, 调整后的  $R^2$  为 0.3314, 说明模型拟合效果良好, 继续使用该 ARIMA 模型预测 2018 年 1 月至 2019 年 6 月的人民币汇率, 结果表示如图 1。

(4) 最后检验模型拟合值的自相关性以证实模型有效, 通过分析各滞后阶数的 Q 统计量和 P 值, 预测残差已经不再体现自相关性, 模型可靠, 故本研究利用 ARIMA (1, 1, 1) 模型预测人民币汇率序列的线性波动部分。

#### 2. GARCH 模型汇率预测效果

与 ARIMA 模型的数据预处理类似, 建立 GARCH 模型之前需要对汇率时间序列平稳

化,本文采用对数差分法进行平稳化。经过对数一阶差分后可以通过ADF检验通过,对其滞后阶数进行估计,可知其自相关阶数 $k$ 在1之后迅速收敛于0,故选取AR(1)模型参数估计,我们采取ARCH-LM方法检验模型ARCH效应,首先检验AR(1)的残差自相关和偏自相关情况,发现所建立的AR(1)拟合残差的PAC和AC均无拖尾现象,说明残差不显著相关。

通过AR(1)模型相关图检验其拟合残差平方的相关性,可知第1、4、5、6、7、10、11、12项的PAC和AC值均较大,说明可能出现ARCH效应的滞后项的阶数为1、4、5、6、7、10、11、12,故本研究对这些阶数进行ARCH-LM检验,发现不同滞后阶数的LM检验的F统计值和LM统计值高于95%临界值,且其P值均小于0.05,可推断该残差序列存在明显的ARCH效应。基于信息最小原则建立GARCH模型,比较不同参数的GARCH模型的AIC、SIC和HQC值,选取最优化模型,即GARCH(1,2)模型。

在构建GARCH(1,2)模型后,需要通过检验残差的ARCH效应来判断模型是否有效,检验方法与上述ARCHLM法相同,选取前12阶滞后项进行LM检验,发现F值是0.2344,对应的P值等于0.9960;LM值等于3.1503,对应的P值等于0.9944,可知经过GARCH(1,1)拟合后的残差已经不存在ARCH效应通过分析GRACH模型拟合残差的各阶滞后项的t统计量和P值证明模型有效,其预测2018年1月至2019年6月人民币对美元汇率的结果如图1所示。

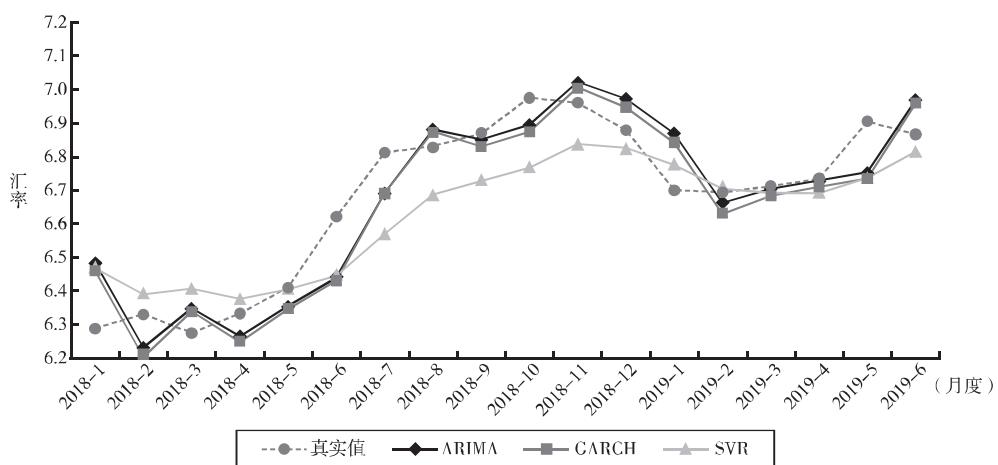


图1 2018年1月至2019年6月人民币对美元汇率预测值

### 3. SVR模型汇率预测效果

SVR模型的关键是核函数的选取、核参数 $g$ 和惩罚系数C的设置。本文选择支持向量回归机中广泛运用的RGB模型作为SVR核函数,运用网格遍历法寻找最优参数组合:核函数中核参数 $g$ ,惩罚系数C。表1展示了不同参数范围下进行网格遍历法参数寻优得到的模型的性能,并且比较了有无对数据进行PCA降维处理的模型性能,可以发现,从宽到窄地选取参数范围和步长值是比较好的做法,同时经过PCA降维处理的数据集能够得到更好的训练结果,通过分析不同参数下SVR模型的均方误差情况,考虑到训练集和测试集的综合表现,如图2所示,选取参数组合 $C=16$ , $g=0.0442$ 作为SVR模型的参数,松弛向量 $\rho$ 对模型影响不大,按照经验取0.01,此时 $R^2$ 和MSE分别为0.9645和0.0027(见表1)。

表 1 不同参数设置及 PCA 过程对 SVR 训练的影响

参数范围及步长	未 PCA 降维			PCA 降维		
	参数组合	R <sup>2</sup>	MSE	参数组合	R <sup>2</sup>	MSE
(-20 : 1 : 20)	(524288, 0.0000)	0.9666	0.0025	(8, 0.125)	0.9642	0.0029
(15 : 1 : 15)	(8, 0.0625)	0.9607	0.0034	(8, 0.125)	0.9642	0.0029
(-10 : 1 : 10)	(8, 0.0625)	0.9607	0.0034	(8, 0.125)	0.9642	0.0029
(-8 : 1 : 8)	(8, 0.0625)	0.9607	0.0034	(8, 0.125)	0.9642	0.0029
(-8 : 0.5 : 8)	(5.6569, 0.0884)	0.9611	0.0035	(16, 0.0442)	0.9645	0.0027
(-8 : 0.1 : 8)	(0.3299, 0.7579)	0.9674	0.0036	(0.4665, 1.1487)	0.9662	0.0036

在确定核函数及运用网格遍历法选定 SVR 参数之后，我们将经过归一化与 PCA 降维的 2010 年 6 月至 2017 年 12 月的汇率及评价指标体系月度数据输入 SVR 模型作为训练数据，并使用该模型对 2018 年 1 月至 2019 年 6 月的人民币对美元月度汇率预测，大部分预测点都在真实值附近，R<sup>2</sup> 达到 0.8009，预测 MSE 为 0.0187，预测效果良好。

#### 四、基于 FIG 和 RF 的汇率预测组合模型

组合模型的建立包括两个步骤：首先，将调试完成的 ARIMA 模型、GARCH 模型、SVR 模型对 2010 年 6 月至 2019 年 6 月人民币对美元汇率的拟合值加入到原有评价指标体系中，通过增加 3 个与人民币汇率波动强相关的指标可以有效提高对人民币汇率预测的精度，同时，由于不同模型的拟合值将带来彼此互相干扰的噪声序列，故对组合指标体系使用 PCA 降维方法预处理；其次，对组合指标体系使用 FIG 预处理，分别对每个信息粒的最大值、平均值和最小值分析，将人民币汇率波动限制在一个既定的范围内，并且适用于长、中、短期不同时间维度的预测要求。

##### 1. 模型评价指标

为了评价汇率预测模型的准确性并便于进行不同模型之间的对比，本文运用六个模型预测效果评价指标评估模型预测性能，它们分别是均方误差（MSE）、平均绝对误差（MAE）、平均相对误差（MAPE）、均方百分比误差（MSPE）、绝对均方根误差（RMSE）和方差（SSE），计算公式如下：

$$\epsilon_{MSE} = \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n} \quad (22)$$

$$\epsilon_{MAE} = \frac{\sum_{i=1}^n |\hat{y}_i - y_i|}{n} \quad (23)$$

$$\epsilon_{MAPE} = \frac{\sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right|}{n} \quad (24)$$

$$\epsilon_{MSPE} = \sqrt{\frac{\sum_{i=1}^n \left( \frac{\hat{y}_i - y_i}{y_i} \right)^2}{n}} \quad (25)$$

$$\epsilon_{RMSE} = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (26)$$

$$\epsilon_{\text{SSE}} = \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (27)$$

其中  $\epsilon$  是模型拟合的误差值,  $\hat{y}_i$  和  $y_i$  分别为序列第  $i$  个 ( $i=1, 2, \dots, n$ ) 模型拟合值和真实值,  $n$  为样本数量。

## 2. FIG 算法

基于 Pedrycz (2005) 提出的模糊信息粒化理论, 本研究中使用三角型模糊粒子对汇率时序数据及各经济指标进行模糊化处理, 以三个月作为时间窗进行模糊处理, 共获得 36 个模糊信息粒子, 信息粒输出可能最高值 (High)、可能中值 (Mid) 和可能最低值 (Low), 可从传统点预测转向区间预测; 通过缩短和扩增时间窗宽度, 可以进行长期或短期预测。图 2 展示了经过模糊信息粒化处理后的 2010 年 6 月至 2019 年 6 月人民币汇率时间序列图像。

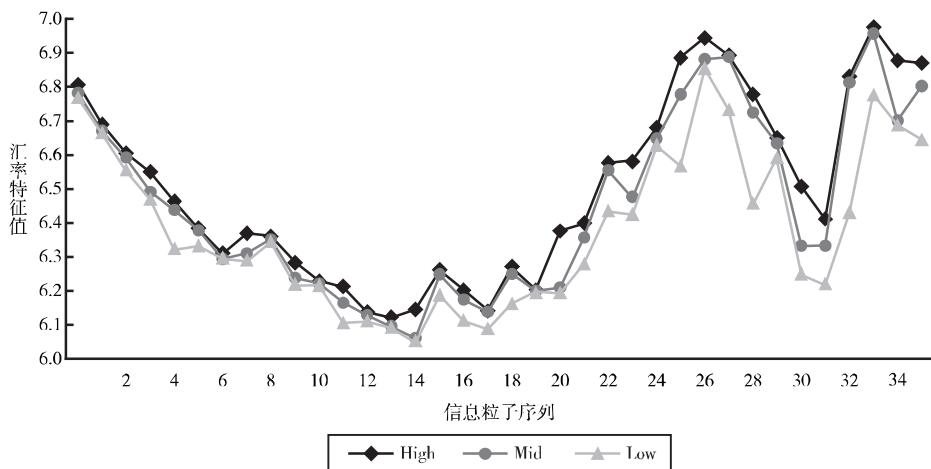


图 2 FIG 处理后人民币对美元汇率信息粒

## 3. RF 模型的构建

RF 包含两个对其性能影响显著的参数: 回归树的棵数  $ntree$  和树节点处随机变量个数  $mtry$ 。适当的参数组合 ( $ntree, mtry$ ) 对 RF 模型的学习能力影响巨大, 最佳参数组合寻优核心思想为网格遍历法, 即通过固定其中一个参数值的同时不断改变另一个参数寻找全局最优解, 具体过程如图 3 所示, 可发现  $ntree$  在 500 以后, 模型性能只与  $mtry$  有关; 当  $ntree$  小于 10 时, RF 性能只与  $ntree$  的取值有关。总体来看, RF 模型的性能随着  $ntree$  的增加而降低, 并且对于不同的  $mtry$  有类似的规律, 然而更大的  $ntree$  和  $mtry$  意味着运算时间的增加, 故选取参数组合 (500, 6) 作为 RF 模型的最优参数, 当对 FIG 处理后的数据建模时, 参数寻优过程与此处相同。

通过求得全局最优的 RF 参数组合 ( $ntree, mtry$ ), 我们可以利用不同形式的人民币汇率及评价指标体系数据进行建模分析, 为了评价单一 RF 模型真实的预测能力, 突出模型组合后对比单一模型的性能提升, 暂且不与其他模型进行组合, 而将 2018 年之前的数据作为训练集, 之后的数据作为测试集进行建模分析, 模型  $R^2$  为 0.9455, MSE 为 0.0037, 通过与真实值的比较说明预测效果良好, 但基于 RF 的组合模型性能能否进一步加强需要更深入的研究。

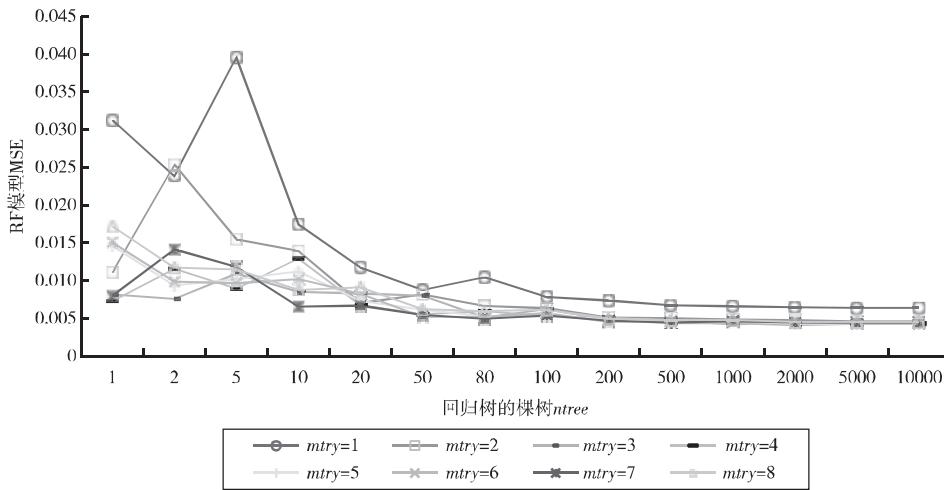


图 3 RF 模型参数寻优结果

基于模型运行精度和运行速度的双重考虑,本文选择最优参数组合构建 RF 模型,为实现将 ARIMA、GARCH 和 SVR 模型有效组合,需要根据 RF 模型计算的单一模型的权重指标 MDG 值分别确定其相对贡献度,发现 SVR、GARCH 和 ARIMA 模型的 MDG 值依次降低 (2.55/2.45/2.24),说明其影响人民币汇率波动的权重依次减弱,SVR 作为机器学习模型擅长解释人民币汇率复杂的非线性和不规则波动,参数化的非线性计量模型 GARCH 模型相对权重同样较大,而线性模型 ARIMA 模型在组合模型中所占比重较少,说明人民币汇率变化是复杂的非线性变化,但线性模型的预测仍必不可少。基于各个单一模型的权重分析,本文将各类模型结果有效结合,并评判其相对贡献程度,但仍需明确的是,RF 作为黑箱模型,任何指标的 MDG 值都会随着数据量和特征属性的变化而改变,故组合模型最终预测值并非单一模型的简单加权平均,而是 500 棵决策树投票的结果。

#### 4. 组合模型与常用汇率预测模型性能对比

(1) 预测结果。本文在使用 FIG 算法对信息粒子进行模糊化处理后,以 RF 为基础的组合模型相比没有进行模糊化处理时整体误差水平更低,将 high、mid、low 三个预测值的平均值作为最终预测值,可以进一步降低人民币汇率的预测误差。如图 4 所示,2018 年 1 月至 2018 年 4 月,人民币汇率在 6.3 附近保持平稳,此时参数模型 ARIMA 和 GARCH 预测效果较差,模拟结果在 6.2 至 6.4 的范围内上下波动且几乎保持一致,原因可能是其仅依据人民币汇率的历史数据做出决策,并未考虑其他经济变量的影响,2017 年底的人民币汇率给了参数模型错误的判断;而非参数模型 SVR 与组合模型预测到保持平稳的人民币汇率值,但总体水平在 6.4 至 6.5 仍然高于真实值。从 2018 年 6 月开始,人民币汇率大幅度下跌并且波动频繁,此时各类模型表现各有优劣,但经过 PCA 降维处理的组合模型明显更优,与表 3 结论保持一致。总而言之,人民币汇率波动是受多方面调控和影响的复杂非线性问题,从任何单一的经济指标很难对其完整分析,同理根据单一预测模型也很难实现精准预测,这也显示了构建汇率预测组合模型的必要性。

结合图 4 可知,对于组合模型的测试时间段,即 2018 年 1 月到 2019 年 6 月,可以发现组合模型对于不同时段的拟合效果不同,例如 2018 年 1 月至 2018 年 6 月,组合模型对人民

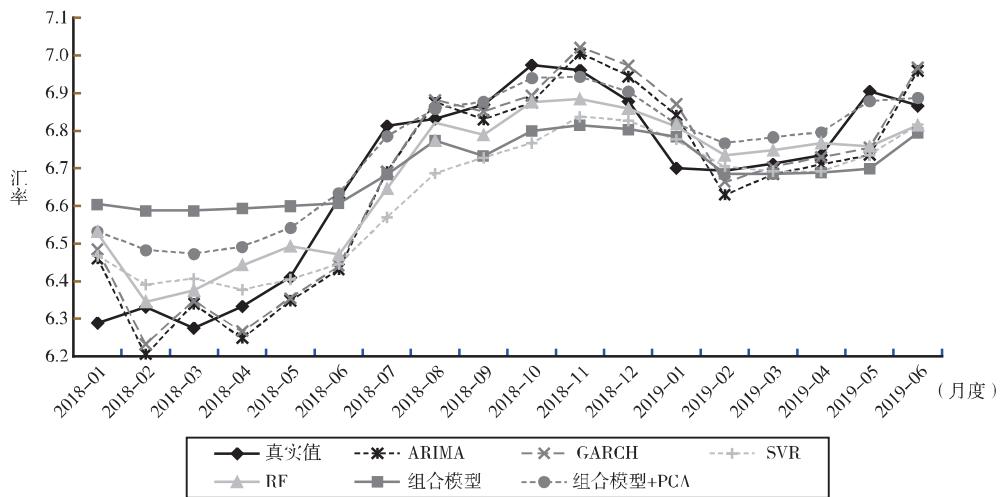


图4 各类汇率预测单一模型与组合模型性能对比

币汇率的拟合效果较差, MSE 为 0.0445, MAE 为 0.1844, MAPE、MSPE、RMSE、SSE 分别为 0.0281、0.0321、0.2112、0.2675; 而在 2018 年 7 月至 2019 年 6 月, 从图中可直观地看出其拟合情况较好, 其评价指标的情况: MSE 为 0.0072; MAE 为 0.0748, 而 MAPE、MSPE、RMSE 和 SSE 则分别为 0.0110、0.0125、0.0852 和 0.0871, 各项指标均明显优于前一时段, 与图中表现一致。为了探究组合模型在不同时段对人民币汇率预测的拟合效果差异及其内在机理, 本文将模型测试时段分为 2018 年 1 月至 2018 年 6 月与 2018 年 7 月与 2019 年 6 月两段, 分别记为时段 1 和时段 2, 以研究不同时段内汇率波动的原因差异。

通过组合模型中 14 个经济指标 MDG 值, 我们根据表 2 选择出对人民币汇率波动的相对影响较大的四个经济指标: 美国 GDP、中国一年期国债利率、中国 M2 和美国 CPI。这四个经济指标符合经典的汇率决定理论。其中, 美国 GDP 和中国一年期国债利率是导致人民币汇率波动相对影响较大的因素, 而中国的 M2 和美国 CPI 的相对影响较小。

表 2 各经济指标影响人民币汇率的权重指标 (MDG)

经济指标	MDG 值
中国 CPI	0.0424
美国 CPI	0.5464
中国 M2	0.5994
美国 M2	0.1440
中国一年期国债利率	1.6459
美联储基本利率	0.3995
中国进出口贸易差额	0.0344
美国进出口贸易差额	0.0860
中国 GDP	0.2139
美国 GDP	2.3210
中国外汇储备	0.2718
美国外汇储备	0.1491
中国消费者信心指数	0.0510
美国消费者信心指数	0.3899

通过分析这四个经济变量在不同时段内的变化情况探讨人民币汇率变化原因。根据图 5, 我们可以发现人民币汇率在时段 1 内贬值速度较快, 而在时段 2 内汇率呈现局部波动, 总体仍呈下降趋势。作为对人民币汇率波动相对影响最大的两个经济指标, 美国 GDP 和中国一年期国债利率在时段 1 内变动相比时段 2 内更大。如图 5 所示, 美国 GDP 在时段 2 内放缓了增长, 斜率由 71.82 降低到 27.59。我国一年期国债利率值也在时段 2 内减缓下降速度, 斜率由 -0.0729 增大到 -0.0358。就其他两个指标而言, 中国的 M2 持续上升, 美国的 CPI 波动较大, 但对于人民币汇率相对影响较少。通过计算组合模型预测值在 2018 年 1 月至 2019 年 6 月与四个主要经济指标的相关系数, 发现其与美国 GDP、中国一年期国债利率、中国 M2 和美国 CPI 的相关系数分别为 0.639、0.732、0.726、0.014, 发现汇率对美国 GDP、中国一年期国债利率和中国 M2 敏感性较强, 且均通过 95% 显著性检验。而随着时段 2 内美国 GDP 和中国一年期国债利率变化速度大幅度减慢, 其对组合模型的影响随着减小, 从而组合模型在时段 2 内表现更加稳定。

本文基于 RF 和 FIG 构建的汇率预测组合模型在时段 2 内各项评价指标均优于时段 1, 而在时段 1 内, ARIMA 模型拟合 MSE 为 0.0157, MAE 为 0.1122, MAPE、MSPE、RMSE、SSE 分别为 0.0175、0.0196、0.1253、0.0943, GARCH 模型拟合的 MSE 为 0.0162, MAE 为 0.1170, MAPE、MSPE、RMSE、SSE 分别为 0.0183、0.0198、0.1273、0.0973, 发现组合模型在本时段内拟合优度甚至劣于线性 ARIMA 模型, 说明在人民币汇率稳定变化的时期, 组合多种非线性和非参数模型的组合模型表现甚至不如线性模型, 这与其他学者的研究一致 (Xie 等, 2015)。而随着 2018 年 7 月 6 日凌晨, 特朗普在空军一号宣布将对价值 340 亿美元的中国商品加征 25% 的额外关税, 意味着“中美贸易战”已经开始, 人民币汇率顿时处于不稳定的动荡外部环境当中, 2019 年 8 月 5 日, 人民币汇率甚至宣布“破 7”, 三个月后央行印发《2019 年第三季度中国货币政策执行报告》, 明确提出完善人民币汇率市场化机制, 进一步深化汇改, 在人民币市场化进程不断加深的背景下, 组合模型表现明显最优, 说明具有很大研究价值。

(2) 预测误差。根据表 3 可知, 对于单一非参数模型 SVR 和 RF, 其在预测期的表现总体差于参数模型, 可能由于人民币汇率评价指标体系带来误差, 宏观经济变量在中短期预测方面的贡献程度低于参数模型所依赖的历史数据, 但仅依靠历史数据建模的参数模型在某些时期可能会带来严重的误差, 比如 2018 年 1 月至 2018 年 6 月, 历史数据所包含的信息是有限且过时的, 本文基于 RF 集成算法将 ARIMA、GARCH、SVR 模型的拟合值分别加入评价指标体系, 使其分别对汇率波动的线性部分、非线性部分与复杂非线性波动做出预测, 期望避免 2018 年 1 月至 2018 年 6 月的“失灵时期”出现, 为了降低多源模型拟合值对 RF 模型造成的噪声干扰, 使用 PCA 方法对数据集进行降维处理, 尽管在 RMSE、SSE 等指标上仍然高于 ARIMA 模型, 但整体上优于单一预测模型。在以季度时间窗宽度为例使用 FIG 算法对时序模糊粒化后, 组合模型输出从点预测转化为区间预测, 若以该波动区间均值作为该时刻预测最终值, 计算其评价指标, 发现 MSE 仅为 0.0070, SSE 仅为 0.1255, 各项指标均在组合模型基础上大幅度下降, 预测波动范围的同时精度有所提高。结合 6 个评价指标的误差分析发现基于 FIG 和 RF 的组合模型对比 ARIMA、GARCH 和 SVR 三个单一模型, 测试时间段内的预测精准度分别提高 15.5%、16.7%、36.6%、较 RF 模型上升 17.0%。且对于 PCA 算法处理的组合模型提高 14.4%, 预测性能良好。

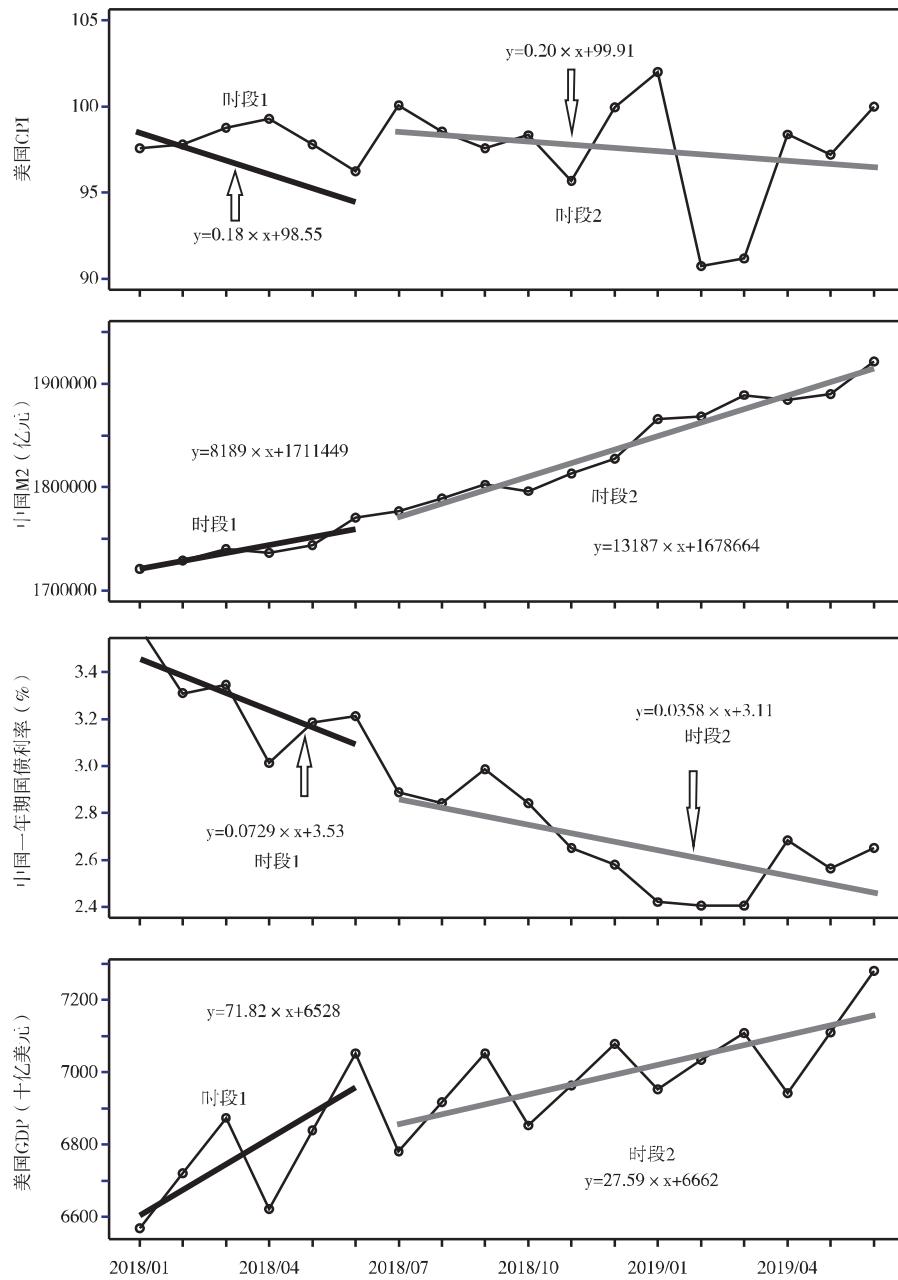


图 5 主要经济指标在时段 1 和时段 2 内的变化情况

表 3

不同模型的汇率预测性能对比

模型	单一模型				组合模型	组合模型 + PCA	组合模型+PCA+FIG			
评价指标	ARIMA	GARCH	SVR	RF	基本组合	基本组合	基本组合 + high	基本组合 + mid	基本组合 + low	基本组合 + FIG 均值
MSE	0.0108	0.0108	0.0159	0.0111	0.0289	0.0109	0.0048	0.0070	0.0037	0.0070
MAE	0.0870	0.0912	0.1041	0.0871	0.1395	0.0781	0.0867	0.1121	0.0941	0.1121

(续)

模型	单一模型				组合模型 + PCA	组合模型+PCA+FIG			
	ARIMA	GARCH	SVR	RF		基本组合 + high	基本组合 + mid	基本组合 + low	基本组合 + FIG 均值
MAPE	0.0131	0.0137	0.0155	0.0131	0.0212	0.0121	0.0132	0.0173	0.0146
MSPE	0.0156	0.0157	0.0187	0.0161	0.0263	0.0165	0.0106	0.0132	0.0093
RMSE	0.1038	0.1041	0.1260	0.1053	0.1701	0.1045	0.0694	0.0835	0.0604
SSE	0.1939	0.1951	0.2856	0.1995	0.5208	0.1966	0.0867	0.1255	0.0657

注：“基本组合”即指在指标体系中加入 ARIMA、GARCH、SVR 模型的拟合值进行基于 RF 的汇率预测模型，其他组合均为在基本组合模型上的衍生。

### 5. 变化时间窗分析

本文基于 FIG 算法研究不同时间窗下组合模型的表现，依次对原时序粒子进行模糊化处理分别得到窗口为 2 个月至 6 个月的信息粒，将其预测波动区间的均值作为最终预测值与真实值比较，采用评价指标描述其预测性能，结果如表 4，其随窗口宽度变化过程如图 6 所示，可以发现当粒化窗口为 3 个月时，各类指标都说明模型性能最好，而随着窗口宽度的增大，模型的预测误差逐渐变大，最大值出现在 4 个月时，此时组合模型的 MSE 为 0.0790，比基本组合模型大 10 倍以上，预测精度最低，但可以看到随着窗口宽度的进一步增大，各项指标呈现下降的趋势，但囿于窗口宽度增大带来的可用数据量急剧减小，更长周期的预测在本研究中不再有意义。

表 4 不同模糊化时间窗下组合模型的预测表现

评价指标	基本组合	基本组合+FIG					
		一个月	两个月	三个月	四个月	五个月	六个月
MSE	0.0070	0.0594	0.0287	0.0790	0.0622	0.0213	
MAE	0.1121	0.2038	0.1523	0.2429	0.2178	0.1107	
MAPE	0.0173	0.0305	0.0229	0.0363	0.0328	0.0165	
MSPE	0.0132	0.0364	0.0254	0.0420	0.0375	0.0218	
RMSE	0.0835	0.2437	0.1693	0.2811	0.2495	0.1460	
SSE	0.1255	0.5345	0.1720	0.3950	0.2490	0.0639	

注：同表 3。

### 6. 稳健性检验

在建立基于 RF 的人民币汇率预测组合模型后，本研究从两个方面对组合模型的稳健性进行分析：(1) 考虑我国 2015 年汇改产生的外生冲击，2015 年汇改以后的数据模拟对现在的汇率变动趋势预测更有效果，故本研究将时间跨度缩小至 2015 年 7 月至 2019 年 6 月，数据来源和预处理方式保持不变。检验结果发现将训练数据全部后移至 2015 年汇改之后，人民币外汇市场化进程加强，ARIMA 和 GARCH 模型参数均达到 95% 置信度显著水平，且组合模型表现良好，总体来说模型通过稳健性检验。(2) 通过选取 SDR 一篮子货币中占比重较大的欧元、英镑和日元，将组合模型中人民币对美元汇率因变量分别替换为人民币对欧元、英镑和日元的汇率月度值，数据来源与预处理方式不变，时间跨度为 2010 年 6 月至 2019 年 6

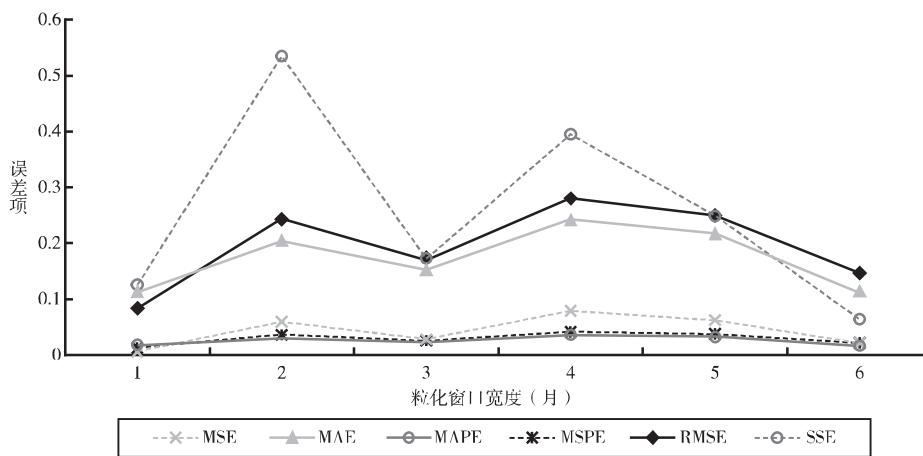


图 6 不同模糊化时间窗下组合模型的预测表现变化

月。当与人民币对美元汇率相关的变量分别被人民币对日元、欧元和英镑的汇率所替代时, GARCH 模型对三种货币都通过了 95% 显著性检验, 但可决系数相对较低, ARIMA 模型对人民币兑英镑汇率拟合参数显著, 且可决系数较大, 对人民币兑日元和欧元汇率仅分别通过 85% 和 95% 显著性检验, 但模型评价指标总体数值较小, 可以认为模型通过稳健性检验。

## 五、研究结论

本文以人民币对美元汇率为例研究其波动规律, 首先, 基于购买力平价理论、利率平价理论、国际收支理论等经典汇率决定理论, 选取中美两国的 CPI、M2、利率、进出口贸易净额、GDP、国家外汇储备、消费者信心指数和上个月度的人民币对美元汇率等 14 个影响汇率波动的宏观经济指标, 并结合 ARIMA、GARCH、SVR 模型的拟合值等短期波动指标构建基于随机森林智能算法的组合模型。其次, 运用 FIG 算法处理进行变周期的区间预测, 研究了 FIG 时间窗宽度变化对组合模型性能的影响。最后, 采取 MSE、MAE、MAPE、MSPE、RMSE、SSE 六个模型评价指标对模型性能对比评估, 并进行了稳健性检验。本文研究得到的主要结论如下:

第一, 汇率预测组合模型相对单一模型的预测精度明显提升, 各误差评价指标均相应减小, 体现了组合模型的优越性。经过 PCA 降维后, 基于 RF 和 FIG 构建的组合模型其汇率预测精度分别优于常用的 ARIMA、GARCH、SVR 单一模型 15.5%、16.7% 和 36.6%。另外, 本文基于 RF 计算各单一模型与宏观经济变量对人民币汇率变化的相对权重, 发现美国 GDP、中国一年期国债利率、中国 M2 和美国 CPI 是导致人民币汇率波动相对影响较大的四个因素。

第二, 本文使用 FIG 算法对人民币汇率时间序列数据进行模糊化处理, 使用组合模型对粒子输出的汇率波动范围进行分析, 预测人民币汇率的波动区间, 以区间均值作为最终预测值对比点预测更接近真实值。当时段宽度为三个月时组合模型预测性能最优, 且其误差有随着时间窗口延长先增大后减小的趋势。可以根据研究目的, 通过修改 FIG 时间窗宽度变换预测的时间周期, 满足短、中、长期不同时间维度的预测要求, 还可以模拟汇率波动区间, 具有现实意义。

第三, ARIMA 模型、GARCH 模型、SVR 模型分别作为参数线性模型、参数非线性

模型和非参数模型中运用最广泛的模型，这三种单一模型对人民币汇率预测效果较好且拟合优度依次下降，但是参数模型和非参数模型分别只在某特定时间段拟合效果较好。组合模型适用于短中期汇率预测，特别是在国际金融风险不断增大的背景下，汇率波动较大的时期，组合模型对于汇率的精准预测更具优势，体现了汇率预测组合模型的优越性。

### 参 考 文 献

- [1] Anastasakis I. , Mort N. , 2009, *Exchange Rate Forecasting Using a Combined Parametric and Non-parametric Self-Organising Modelling Approach* [J], Expert Systems with Applications, 36, 12001~12011.
- [2] Abreu R. J. , Souza R. M. , Oliveira J. G. , 2019, *Applying Singular Spectrum Analysis and Arima-Garch for Forecasting Eur/Usd Exchange Rate* [J], Revista de Administração Mackenzie, 20, eRAMF190146.
- [3] Aguilar J. , Nydahl S. , 2000, *Central Bank Intervention and Exchange Rates: the Case of Sweden* [J], Journal of International Financial Markets Institutions & Money, 10 (3~4), 303~322.
- [4] Arifovic J. , 1996, *The Behavior of the Exchange Rate in the Genetic Algorithm and Experimental Economies* [J], Journal of Political Economy, 104 (3), 510~541.
- [5] Barunik J. , Krehlik T. , Vacha L. , 2016, *Modeling and Forecasting Exchange Rate Volatility in Time-Frequency Domain* [J], European Journal of Operational Research, 251 (1), 329~340.
- [6] Behnamian A. , Millard K. , Banks S. N. , White L. , Richardson M. , Pasher J. , 2017, *A Systematic Approach for Variable Selection with Random Forests: Achieving Stable Variable Importance Values* [J], IEEE Geoscience and Remote Sensing Letters, 14 (11), 1988~1992.
- [7] Bhargava V. , Dania V. , Malhotra D. K. , 2011, *Covered Interest Rate Parity among BRIC Nations* [J], Journal of Business and Economic Study, 17 (1), 37.
- [8] Bollerslev T. , 1986, *Generalized Autoregressive Conditional Heteroskedasticity* [J], Journal of Econometrics, 31 (3), 307~327.
- [9] Boulesteix A. L. , Bender A. , Bermejo J. L. , Strobl C. , 2012, *Random Forest Gini Importance Favours SNPs with Large Minor Allele Frequency: Impact, Sources and Recommendations* [J], Briefings in Bioinformatics, 13 (3), 292~304.
- [10] Box G. E. P. , Jenkins G. M. , Reinsel G. C. , 1976, *Time Series Analysis: Forecasting and Control* [M], San Francisco: Holden-Day Press.
- [11] Breiman L. , 2001, *Random Forests* [J], Machine Learning, 45, 5~32.
- [12] Cao L. , 2003, *Support Vector Machines Experts for Time Series Forecasting* [J], Neurocomputing, 51, 321~339.
- [13] Chen H. , Chen F. , Shi K. , Feng Q. , 2015, *Near-infrared Analysis of Fishmeal Protein Based on Random Forest* [J], Transactions of the Chinese Society for Agricultural Machinery, 46 (5), 233~238.
- [14] Chen H. Z. , Tang G. Q. , Ai W. , Xu L. L. , Cai K. , 2015, *Use of Random Forest in FTIR Analysis of LDL Cholesterol and Tri-Glycerides for Hyperlipidemia* [J], Biotechnology Progress, 31 (6), 1693~1702.
- [15] Chen S. , Haerdle W. K. , Jeong K. , 2010, *Forecasting Volatility with Support Vector Machine-Based GARCH Model* [J], Journal of Forecasting, 29 (4), 406~433.
- [16] Cheung Y. W. , Chinn M. D. , Pascual A. G. , 2005, *Empirical Exchange Rate Models of the Nineties: Are Any Fit to Survive?* [J], Journal of International Money and Finance, 24 (7), 1150~1175.
- [17] Engle R. F. , 1982, *Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation* [J], Econometrica, 50 (4), 987~1007.
- [18] Hajizadeh E. , Mahootchi M. , Esfahanipour A. , Massahi M. K. , 2019, *A New NN-PSO Hybrid*

*Model for Forecasting Euro/Dollar Exchange Rate Volatility* [J], Neural Computing and Applications, 31, 2063~2071.

[19] Han H. , Guo X. , Yu H. , 2016, *Variable Selection Using Mean Decrease Accuracy and Mean Decrease Gini Based on Random Forest* [C], in Proceedings of 2016 IEEE 7th International Conference on Software Engineering and Service Science (Icsess 2016), IEEE.

[20] He A. W. W. , Wan A. T. K. , 2009, *Predicting Daily Highs and Lows of Exchange Rates: a Cointegration Analysis* [J], Journal of Applied Statistics, 36 (11), 1191~1204.

[21] He K. , Lai K. K. , Yen J. , 2010, *A Hybrid Slantlet Denoising Least Squares Support Vector Regression Model for Exchange Rate Prediction* [J], Procedia Computer Science, 1 (1), 2397~2405.

[22] Khashei M. , Bijari M. , Ardali G. A. R. , 2009, *Improvement of Auto-Regressive Integrated Moving Average models using Fuzzy logic and Artificial Neural Networks (ANNs)* [J], Neurocomputing, 72 (4~6), 956~967.

[23] Kampichler C. , Wieland R. , Calmé S. , Weissenberger H. , Arriaga-Weiss S. , 2010, *Classification in Conservation Biology: A Comparison of Five Machine-Learning Methods* [J], Ecological Informatics, 5 (6), 441~450.

[24] Kuan C. M. , Liu T. , 1995, *Forecasting Exchange Rates Using Feedforward and Recurrent Neural Networks* [J], Journal of Applied Econometrics, 10 (4), 347~364.

[25] Ibrahim I. A. , Khatib T. , 2017, *A Novel Hybrid Model for Hourly Global Solar Radiation Prediction Using Random Forests Technique and Firefly Algorithm* [J], Energy Conversion and Management, 138, 413~425.

[26] Ismailov A. , Rossi B. , 2018, *Uncertainty and Deviations from Uncovered Interest Rate Parity* [J], Journal of International Money and Finance, 88, 242~259.

[27] Makridakis S. , Winkler R. L. , 1983, *Averages of Forecasts: Some Empirical Results* [J], Management Science, 29 (9), 987~996.

[28] Maia A. L. S. , de Carvalho F. de A. T. , Ludermir T. B. , 2008, *Forecasting Models for Interval-Valued Time Series* [J], Neurocomputing, 71 (16~18), 3344~3352.

[29] Menze B. H. , Kelm B. M. , Masuch R. , Himmelreich U. , Bachert P. , Petrich W. , Hamprecht F. A. , 2009, *A Comparison of Random Forest and Its Gini Importance with Standard Chemometric Methods for the Feature Selection and Classification of Spectral Data* [J], Bioinformatics, 10, 213.

[30] Nembrini S. , Koenig I. R. , Wright M. N. , 2018, *The Revival of the Gini Importance?* [J], Bioinformatics, 34 (21), 3711~3718.

[31] Pai P. F. , Lin C. S. , Hong W. C. , Chen C. T. , 2006, *A Hybrid Support Vector Machine Regression for Exchange Rate Prediction* [J], International Journal on Information and Management Sciences, 17 (2), 19~32.

[32] Panda C. , Narasimhan V. , 2003, *Forecasting Daily Foreign Exchange Rate in India with Artificial Neural Network* [J], Singapore Economic Review, 48 (2), 181~199.

[33] Pedrycz W. , 2005, *Knowledge-Based Clustering: From Data to Information Granules* [M], New York: Wiley-Interscience.

[34] Rout M. , Majhi B. , Majhi R. , Panda G. , 2014, *Forecasting of Currency Exchange Rates Using an Adaptive ARMA Model with Differential Based Evolution* [J], Journal of King Saud University-Computer and Information Sciences, 26 (1), 7~18.

[35] Santos A. A. P. , da Costa Jr N. C. A. , Coelho L. dos S. , 2007, *Computational Intelligence Approaches and Linear Models in Case Studies of Forecasting Exchange Rates* [J], Expert Systems with Applications, 33 (4), 816~823.

[36] Sermpinis G. , Dunis C. , Laws J. , Stasinakis C. , 2012, *Forecasting and Trading the EUR/USD Exchange Rate with Stochastic Neural Network Combination and Time-Varying Leverage* [J], Decision Sup-

port Systems, 54 (1), 316~329.

[37] Sermpinis G., Stasinakis C., Theofilatos K., Karathanasopoulos A., 2015, *Modeling, Forecasting and Trading the EUR Exchange Rates with Hybrid Rolling Genetic Algorithms-Support Vector Regression Forecast Combinations* [J], European Journal of Operational Research, 247 (3), 831~846.

[38] Sun H., Gui D., Yan B., Liu Y., Liao W., Zhu Y., Lu C., Zhao N., 2016, *Assessing the Potential of Random Forest Method for Estimating Solar Radiation Using Air Pollution Index* [J], Energy Conversion and Management, 119, 121~129.

[39] Tseng F. M., Tzeng G. H., Yu H. C., Yuan B. J. C., 2001, *Fuzzy ARIMA Model for Forecasting the Foreign Exchange Market* [J], Fuzzy Sets and Systems, 118 (1), 9~19.

[40] Vapnik V., 1998, *Statistical Learning Theory* [M], New York: Wiley.

[41] Xie C., Mao Z., Wang G. J., 2015, *Forecasting RMB Exchange Rate Based on a Nonlinear Combination Model of ARFIMA, SVM, and BPNN* [J], Mathematical Problems in Engineering, 635345.

[42] Yuan Y., 2013, *Forecasting the Movement Direction of Exchange Rate with Polynomial Smooth Support Vector Machine* [J], Mathematical and Computer Modelling, 57 (3~4), 932~944.

[43] Zadeh L. A., 1979, *Fuzzy Sets and Information Granularity* [A], in Gupta M., Ragade R., and Yager R. R., (eds.), *Advances in Fuzzy Set Theory and Applications* [C], Amsterdam, the Netherlands: North-Holland.

[44] Zorzi M. C., Muck J., Rubaszek M., 2016, *Real Exchange Rate Forecasting and PPP: This Time the Random Walk Loses* [J], Open Economics Review, 27, 585~609.

[45] 毕玉江、王双成:《汇率预测方法及比较:基于贝叶斯平均分类回归模型的检验》[J],《统计与决策》2016年第3期。

[46] 陈诗一:《汇率预测:一个新的非参数支持向量方法》[J],《数量经济技术经济研究》2007年第5期。

[47] 邓贵州、李艳丽:《汇率基本面模型对人民币汇率的预测能力》[J],《数量经济技术经济研究》2016年第9期。

[48] 奉国和:《SVM分类核函数及参数选择比较》[J],《计算机工程与应用》2011年第03期。

[49] 傅魁、郭志颖:《基于MEEMD组合模型的汇率预测》[J],《统计与决策》2018年第11期。

[50] 惠晓峰、柳鸿生、胡伟、何丹青:《基于时间序列GARCH模型的人民币汇率预测》[J],《金融研究》2003年第5期。

[51] 龚锐、陈仲常、杨栋锐:《GARCH族模型计算中国股市在险价值(VaR)风险的比较研究与评述》[J],《数量经济技术经济研究》2005年第7期。

[52] 刘进、郭进超:《中国制造业PMI指数的预测与分析》[J],《统计与决策》2019年第15期。

[53] 李志超、刘升:《基于ARIMA模型、灰色模型和回归模型的预测比较》[J],《统计与决策》2019年第23期。

[54] 林升梁、刘志:《基于RBF核函数的支持向量机参数选择》[J],《浙江工业大学学报》2007年第2期。

[55] 李欣珏、牛霖琳:《汇率预测及其经济基本面:基于多元自适应可变窗算法的构建》[J],《统计研究》2019年第9期。

[56] 李晓新、张屹山:《基于小波变换的模糊信息粒化支持向量回归模型及其应用研究》[J],《数量经济研究》2019年第4期。

[57] 马晓君、董碧滢、王常欣:《一种基于PSO优化加权随机森林算法的上市公司信用评级模型设计》[J],《数量经济技术经济研究》2019年第12期。

[58] 孙轶轩、邵春福、计寻、朱亮:《基于ARIMA与信息粒化SVR组合模型的交通事故时序预测》[J],《清华大学学报(自然科学版)》2014年第3期。

[59] 魏巍贤:《人民币汇率决定模型的实证分析》[J],《系统工程理论与实践》2000年第3期。

[60] 吴孝情、赖成光、陈晓宏、任秀文:《基于随机森林权重的滑坡危险性评价:以东江流域为例》[J],《自然灾害学报》2017年第5期。

- [61] 谢赤、杨妮、孙柏:《汇率时间序列非线性特征分析及实证研究》[J],《系统工程》2008年第10期。
- [62] 徐立本、罗士勋:《购买力平价理论在人民币汇率预测中的应用》[J],《吉林大学社会科学学报》2005年第3期。
- [63] 张一、惠晓峰:《基于奇异谱分析的汇率预测研究》[J],《统计与决策》2012年第6期。
- [64] 张忠杰:《ARIMA模型在汇率预测中的应用》[J],《全国商情(经济理论研究)》2005年第7期。
- [65] 郑振龙、黄蕙舟:《波动率预测:GARCH模型与隐含波动率》[J],《数量经济技术经济研究》2010年第1期。

## Research on Exchange Rate Forecasting Integrated Model Based on Random Forest and Fuzzy Information Granulation

Xiong Jinghua<sup>1,2</sup> Ru Jing<sup>1</sup>

(1. School of Economics and Finance, South China University of Technology;

2. School of Water Resources and Hydropower Engineering, Wuhan University)

**Research Objectives:** This paper is committed to using intelligent algorithm to improve the accuracy of exchange rate prediction and to provide reference for cross-border capital flow and exchange rate risk prevention. **Research Methods:** Random Forest (RF) and Fuzzy Information Granulation (FIG) in machine learning frontier field are introduced to build an integrated model with more accurate prediction ability of exchange rate. **Research Findings:** The results show that the accuracy of the integrated model based on RF and FIG is better than that of the commonly used ARIMA, GARCH and SVR models 15.5%, 16.7% and 36.6% respectively; the model based on the training of fuzzy information particles can predict the exchange rate fluctuation range rather than fitted value; the model performs best with the quarterly granulation window, and the error increases followed by decreasing trend as window grows. **Research Innovations:** The first advantage of Random Forest (RF) is used to reasonably allocate variable weights and distribute the predicted values of three single models into the integrated model, combining with PCA and FIG method, thus enhancing the accuracy of exchange rate prediction. The second advantage is to use Fuzzy Information Granulation to transform the forecast of exchange rate fluctuation from point forecast to interval prediction, and the time period of prediction can be changed by modifying the time window. **Research Value:** With the deepening of RMB internationalization and exchange rate marketization, the fluctuation of exchange rate is strengthened. Accurate prediction of exchange rate is of great significance to both macro decision-making and micro economic activities.

**Key Words:** Exchange Rate Forecasting; Random Forest; Fuzzy Information Granulation; Integrated model

**JEL Classification:** F31

(责任编辑:王喜峰)

# 基于结构突变的动态高阶矩 Realized EGARCH 模型及应用<sup>①</sup>

蔡光辉 廖亚琴

(浙江工商大学统计与数学学院)

**研究目标:** 考虑资产收益率条件高阶矩的动态特征以及突发事件对于金融市场的影响, 构建基于结构突变的动态高阶矩 Realized EGARCH 模型, 对创业板市场波动率进行预测和风险度量。**研究方法:** 在 Wu 等 (2020) 提出的 Realized EGARCH-SK 模型的基础上, 将残差拓展为偏 t 分布, 同时应用修正的 ICSS 算法识别结构突变点, 将其作为虚拟变量引入动态高阶矩 Realized EGARCH 模型中, 并应用稳健损失函数以及 (非) 条件覆盖检验来综合比较各模型的波动率预测精度和 VaR 预测准确性。**研究发现:** 考虑条件偏度和峰度动态效应以及结构突变因素的 Realized EGARCH 模型有助于提高模型的拟合能力、波动率的预测精度和风险度量的准确性; Gram-Charlier 扩展分布在模型的拟合能力和 VaR 预测的表现上明显不如偏 t 分布。**研究创新:** 将残差拓展为偏 t 分布同时加入结构突变因素有效改进波动率模型的拟合、预测和风险度量效果。**研究价值:** 丰富了动态高阶矩高频波动率模型, 结构突变的监测和纳入可为金融投资者和风险管理者的投资决策提供实质性参考。

**关键词** 偏 t 分布 结构突变 修正的 ICSS 算法 动态高阶矩 Realized EGARCH 模型

**中图分类号** F830 **文献标识码** A

## 引言

基于高频数据的波动率建模方法一直是金融领域中的热点问题之一。Andersen 和 Bollerslev (1998) 首次提出基于高频数据全新的非参数波动率建模方法——已实现波动率 (Realized Volatility, RV), 将波动率的估计量设定为日内收益率的平方和, 成功推进了金融高频数据的研究进展。

Hansen 等 (2012) 提出 Realized GARCH 模型, 通过新增测量方程将杠杆函数和已实现测度引入 GARCH 模型中, 用来说明已实现测度和杠杆效应对资产收益率和条件波动率的潜在影响, 研究表明, Realized GARCH 模型可以同时考虑日内高频信息和日间中低频信息, 其波动率预测效果要优于传统的 GARCH 类模型。此后, 基于 Realized GARCH 模型的研究和拓展成为波动率预测和风险度量的主流方向。Hansen 等 (2012) 提出的 Realized

<sup>①</sup> 本文获得国家社科基金 2019 年“高频金融数据统计测度模型的拓展研究”(19BTJ013) 的资助。