

DOI:10.16515/j.cnki.32-1745/c.2019.04.004

# 基于经验模态分解和 ARMA 模型的 国际航空油价实证分析 ——以港湾石油航空燃油价格数据为例

高 伦<sup>1</sup>, 张心成<sup>2</sup>

(1. 奥斯特拉发技术大学经济学院, 奥斯特拉发 捷克共和国 70200;  
2. 中南财经政法大学统计与数学学院, 湖北 武汉 430073)

**摘要:** 价格数据数值与趋势的准确预测一直是金融风险量化控制的一大难题。在国际油价受外部因素影响剧烈波动的背景下, 针对航空燃油价格预测问题, 提出一种基于经验模态分解(EMD)和自回归滑动平均模型(ARMA)的非线性混合预测方法。研究结果表明, EMD-ARMA 组合模型对非平稳时间序列信号的预测有效, 精度相比较单一的 ARMA 模型有显著提高。

**关键词:** 组合预测; 经验模态分解; ARMA; 聚类; 过度分解

中图分类号: F831.5; F222.3

文献标识码: A

文章编号: 1673-131X(2019)04-0015-06

## The Empirical Analysis of International Aviation Oil Price Based on Empirical Mode Decomposition and ARMA Model: Taking the Aviation Oil Price Data of Harbor Oil as an Example

GAO Lun<sup>1</sup>, ZHANG Xin-cheng<sup>2</sup>

(1. VSB-Technical University of Ostrava, Ostrava 70200, Czech Republic;  
2. Zhongnan University of Economics and Law, Wuhan 430073, China)

**Abstract:** The accurate prediction of price data values and trends has always been a major problem in the quantitative control of financial risks. In the context of the international oil price being fluctuated by external influences in recent years, a nonlinear hybrid prediction method based on empirical mode decomposition (EMD) and autoregressive moving average model (ARMA) is proposed for the prediction of aviation kerosene price. The experimental results of the paper show that the EMD-ARMA combined model is effective for predicting non-stationary time series signals, and the accuracy is significantly improved compared with the single ARMA model.

**Key words:** combined forecasting; empirical mode decomposition(EMD); ARMA; clustering; excessive decomposition

随着页岩油的大规模开采, 全球原油产量大增, 与此同时, 石油输出国组织宣布不减产, 由此导

收稿日期: 2019-08-15

基金项目: 江苏省望云智库省级项目“关于国际贸易战略研究”(2019SHJ86)

作者简介: 高伦(1995-), 男, 江苏淮安人, 博士研究生, 主要从事公司风险量化、期权定价、数量经济研究。

致原油市场供给与需求失衡。2018 年至今,影响国际油价的不稳定因素增多,给油价带来更多的不确定性,WTI 原油期货价格更是从 2018 年 12 月 24 日的 42.53 美元每桶上升到目前的 63.10 美元每桶(截至 2019 年 5 月 20 日)。国际油价的剧烈波动直接影响了相关企业甚至是国家的收入。为了抑制油价的剧烈波动,石油输出国组织国家纷纷采取行动试图维持自身收入的稳定。相关企业更是纷纷采取措施,如使用期货期权交易等,试图对冲因油价波动带来的风险。

根据国际航空运输协会的预测,2019 年全球航空运输业净利润将达 355 亿美元,较 2018 年增长 32 亿美元。燃油成本预计占航空公司平均运营成本的 24.2%,因此油价下降导致的燃油成本下降是驱动盈利上涨的重要因素之一。航空公司一方面通过选择不同市场间较低价格的航空燃油来降低燃油成本,另一方面也通过对油价走势进行预测,提前购买期货期权以规避油价涨跌带来的成本变动。

对商品期货价格的准确预测有助于企业降低成本,减少风险。对于在市场上进行交易的商品期货价格的波动而言,价格的时间序列是研究对象所有信息的载体,信号采集和时频分析是预测分析的重要内容。如果将从市场采集的时间序列直接作为预测的信号源,将不可避免地受到非信息噪音或者信息间相互作用的影响,进而影响预测精度。有效抑制无信号噪音、突出有效信号、减少信号间相互干扰,就成了预测过程中必不可少的步骤。因而,对时间序列信号进行预处理对提升预测的精度具有十分重要的意义。

## 一、模型介绍

### (一)经验模态分解

经验模态分解是一种自适应信号分解方法,可以逐步过滤原始序列中存在的不同尺度或趋势分量,以获得具有相同特征尺度的本征模态分量。其中心思想是将信号分解成几个相对平稳的、不相关的本征模函数(IMF)。通常认为 IMF 应满足以下两个条件:

第一,IMF 在整个时间范围内,局部极值点数必须等于和过 0 点的数目,或最多相差一个。

第二,在任何时间点,信号的局部最大值(上包络线)和局部最小值(下包络线)所定义的局部均值

为 0。

简而言之,IMF 是一个均值接近 0、没有明显趋势的时间序列,其性质符合传统时间序列分析的要求。因此,可以使用 EMD 分解非平稳时间序列以获得一系列 IMF,然后进行分析。与此同时,在完成分解后,对于非平稳时间序列,模型产生的剩余量一般包含一定的趋势,称为趋势项,其反映了原始时间序列信号的总体趋势。经验模态分解的基本步骤被广泛应用于工程领域,具体分解过程如下。

第一,搜索原始信号  $x(t)$  的极值点,并将所有最大值和最小值点与三次样条函数连接,以获得  $x(t)$  的上下包络线,分别表示为  $x_{\max}(t)$  和  $x_{\min}(t)$ 。

第二,计算上下包络的均值  $w_1(t)$ 。

$$w_1(t) = \frac{[x_{\max}(t) + x_{\min}(t)]}{2} \quad (1)$$

第三,计算信号  $x(t)$  和包络均值  $w_1(t)$  之间的差值  $d(t)$ 。

$$d(t) = x(t) - w_1(t) \quad (2)$$

第四,判定  $d(t)$  是否满足 IMF 的两个条件。如果  $d(t)$  满足条件,则  $d(t)$  是信号  $x(t)$  的第一个分量,即  $IMF_1$ ;如果不满足条件,则使用  $d(t)$  作为新的原始信号并重复上述步骤直到满足条件。

第五,计算残差信号  $r_1$ 。

$$r_1 = d(t) - IMF_1 \quad (3)$$

第六,使用  $r_1$  作为新的信号源,重复步骤 1—3 并连续分解信号以获得满足条件的  $IMF_i$ ,直到残差  $r_n$  为单调函数或者达到人为设置  $n$  阶时,停止分解。此时,原始信号  $x(t)$  可以表示为  $i$  个 IMF 和残差值  $r_n$  的和。

$$x(t) = \sum_{i=1}^n IMF_i + r_n \quad (4)$$

EMD 分解基于三个假设:第一,任何数据信号均可以分解成几个 IMF 分量和  $r$ ;第二,每个 IMF 分量可以是线性的或非线性的,局部 0 点和极值点的数量是相同的,并且上下包络线关于时间轴是对称的;第三,信号可以包含几个 IMF 分量,当序列极值点不明显时,可以通过差分运算找到极值点<sup>[1-2]</sup>。

### (二)聚类分析

经过 EMD 分解所得出的本征模函数和残值本身就拥有相当的关联性。由于 EMD 是工程学常用模型,未针对金融领域的时间序列分解进行特殊优化,可能存在对原始数据进行过度分解的问题,造成后续建模的不确定性。因此,本文使用 K-

medoids 聚类法和层次聚类对所有本征模函数进行聚类分析,将特征类似的项合并为一类,在后续建模中与未经过聚类的数据进行对比,以判断是否存在对于数据的过度分解。

1. K-medoids 聚类。K-medoids 聚类的判定依赖于距离的远近,具体计算流程如下:所有样本最初分为 K 类,从数据集中随机选取  $k$  个数据点作为初始质心;对集合中每一个数据,计算每个质心的距离,距离接近于哪个质心就属于哪个质心;每一个质心下都聚集了很多数据,再通过算法选出新的质心;如果新旧质心之间的距离小于某一个设置的阈值(表示重新计算的质心的位置变化不大,逐渐稳定或收敛),可认为聚类已经达到预期的效果,停止计算;如果新旧质心之间的距离变化很大,需要迭代 2—4 步骤<sup>[3]</sup>。

与 K-means 聚类不同的是, K-medoids 聚类算法使用中位数作为聚点,克服了因为使用均值为聚点而导致的 K-means 算法对极值较敏感的缺点,是在 K-means 聚类算法基础上的改进。K-medoids 聚类使用绝对差值(SAD)来判断聚类结果的优劣,在  $n$  维欧几里德空间中,绝对差值的计算公式为

$$\begin{aligned} SAD &= \sum_{m=1}^k \sum_{p_i \in c_i} dist(p_i, o_i) \\ &= \sum_{m=1}^k \sum_{p_i \in c_i} \sqrt{(p_{ij} - o_{ij})^2} \quad (5) \end{aligned}$$

目前, K-medoids 聚类较为常用的是围绕中心点划分法(PAM)。使用 PAM 方法进行处理,可以指定最大迭代次数的参数<sup>[4]</sup>,并在迭代过程中,基于贪婪策略,选择产生最高质量群集的分区;在迭代中每次交换中心点和非中心点,然后将非中心点分配到最近的中心点;计算出的 SAD 值越小,聚类质量越好,如此持续迭代直到找到最佳分割。PAM 方法计算聚类的具体过程如下:从要聚类的数据集中随机选择  $k$  个点作为初始中心点;将要聚类的数据点集中的点分配到最近的中心点;进入迭代过程,直到群集质量满足指定阈值。

2. 层次聚类。层次聚类是通过推算不同数据间的相似度,从而创建一棵有多个层级嵌套的聚类树。通过给定的  $N$  个数据的数据集和  $N \times N$  距离矩阵,层次聚类的基本算法如下<sup>[5]</sup>:将每个数据点视为一个簇,并且簇之间的距离(相似)等于相应数据点的距离;找到最接近(最相似)的两个簇并合并;计算新生成的聚类与每个原始聚类之间的距离

(文章使用平均连结聚合演算法实现,平均连结聚合演算法的距离度量是选择两种类型数据对象之间的平均距离);重复步骤 2 和 3,直到所有数据都聚集到一个群集中或达到主观需求的数量。

### (三)ARMA 模型

ARMA 模型由于简单易懂、适用面广和具有极强的灵活性成为目前时间序列预测中运用较为广泛的模型之一。其建模和预测包括四个步骤:数据的平稳化处理;模型识别,即确定模型的滞后阶数  $p$  和  $q$ ;参数估计和模型诊断与测试(包括参数的显著性检验和残差的随机性检验);使用所选择的适当参数的模型进行预测并进行测试。

自回归移动平均模型 ARMA( $p, q$ )如果满足时间序列  $X_n$ :

$$X_n = X - \varphi_1 X_{n-1} - \dots - \varphi_p X_{n-p} = \varepsilon_n - \theta_1 \varepsilon_{n-1} - \dots - \theta_q \varepsilon_{n-q} \quad (6)$$

那么时间序列  $X_n$  服从  $p, q \in (1, 2, 3, \dots)$  阶和  $\varepsilon_n \sim N(0, \sigma_\varepsilon^2)$  的自回归移动平均模型 ARMA( $p, q$ )。其中,  $\varphi_1, \dots, \varphi_p$  是自回归回归系数,  $\theta_1, \dots, \theta_q$  是移动平均系数。当  $p$  或  $q$  为 0 时,模型退化为 MA 或 AR。完整的预测过程如下<sup>[6]</sup>:

1. 对各个 IMF 和趋势项  $r$  进行平稳性检验。如果信号显示为非平稳序列,则通过差分方法对信号进行预处理。

2. 识别模型。对应于数据的时间序列预测模型由数据的统计特性确定,其主要形式是 ARMA( $p, q$ )、AR( $p$ )和 MA( $q$ ),通过计算测量数据的自相关函数和偏自相关函数来确定自所适应模型。

自协方差函数为

$$\hat{\gamma}_k = \frac{1}{N} \sum_{j=1}^{N-k} X_j X_{j+k} \quad (7)$$

自相关函数为

$$\hat{\rho}_k = \frac{\gamma_k}{\gamma_0} \quad (8)$$

偏自相关函数为

$$\begin{cases} \hat{\alpha}_{11} = \hat{\rho}_1 \\ \hat{\alpha}_{k+1, k+1} = (\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\rho}_{k+1-j} \hat{\alpha}_{kj}) \times (1 - \sum_{j=1}^k \hat{\rho}_j \hat{\alpha}_{kj})^{-1} \\ \hat{\alpha}_{k+1, j} = \hat{\alpha}_{kj} - \hat{\alpha}_{k+1, k+1} \times \hat{\alpha}_{k, k-j+1} \end{cases} \quad (9)$$

通常,通过判断  $\hat{\rho}_k$  和  $\hat{\alpha}_k$  的截断来识别模型。

3. 估计模型的阶数和参数。在确定模型后,使用 Akaike 信息标准(AIC)进行选择、定阶。对于

ARMA( $p, q$ ) 模型,  $L$  是模型的最大似然, 使用最大似然估计模型的参数。AIC 标准函数为

$$AIC(p, q) = -2\ln[L] + 2r \approx N\ln(\hat{\sigma}_a^2) + 2r \quad (10)$$

式中,  $r = p + q$  是模型的独立参数的数量;  $\hat{\sigma}_a^2$  是残差方差的最大似然估计。通常用样本大小为  $N$  的 AIC 标准函数表示为

$$AIC(p, q) = \ln[\hat{\sigma}_a^2] + 2r/N \quad (11)$$

当  $AIC(p, q)$  的值最小时,  $(p, q)$  是最佳拟合模型的阶数。参数估计方法主要有矩估计方法、最小二乘估计方法和最大似然法。本文采用最大似然估计方法, 充分考虑每个数据的分布信息, 计算精度较高。

4. 建模后将模型进行适应性测试。本文采用 Q 统计量检验模型的适应性。

## 二、复合模型实证分析

本文使用 ARMA 模型对 1990 年 4 月 2 日至 2018 年 10 月 22 日的来自普氏能源资讯的 7 185 个海湾石油航空燃油价格数据进行实证分析。

### (一) 经验模态分解

根据算法的设置, 经验模态分解将自动分解信号数据, 并根据频率将 IMF 从高到低排列(图 1—图 4), 图中横坐标为时间, 纵坐标为信号强度。

从图 2 可以看出, 在对数据信号进行 EMD 分解后, 生成 10 个 IMF 和趋势项  $r$ 。每个 IMF 分量曲线围绕零均值线在局部最大值和局部最小值间



图 1 原始信号(Matlab)




图 2 IMF1-10(Matlab)



图 3 残值(Matlab)




图 4 重组后的信号和原始信号

接近对称形式地波动, 10 个 IMF 的周期从短到长, 即频率从高到低。趋势项在一定程度上反映了原始序列的基础信号特征, 逐步提升略有波动, 这与对原始信号序列的观察一致。

在对每个分量进行计算后, 得到皮尔逊相关系数(PCCs)、方差、方差贡献率、最大值、最小值和中值(表 1)。其中,  $r$  的方差贡献率是分解所得结果中最大的, 这表明趋势项可以反映未分解价格曲线的基础波动情况。

表 1 数据统计学特征

指标	相关系数	方差	方差贡献率	最大值	最小值	中值
IMF <sub>1</sub>	0.017 9	0.000 4	0.000 6	0.381 0	-0.380 2	-0.000 2
IMF <sub>2</sub>	0.023 6	0.000 7	0.001 0	0.535 1	-0.495 7	-0.000 2
IMF <sub>3</sub>	0.036 8	0.000 9	0.001 2	0.288 7	-0.292 3	-0.000 1
IMF <sub>4</sub>	0.019 5	0.002 1	0.002 8	0.338 3	-0.348 4	-0.000 2
IMF <sub>5</sub>	0.050 4	0.003 2	0.004 4	0.264 6	-0.281 0	0.000 0
IMF <sub>6</sub>	0.166 7	0.007 8	0.010 7	0.444 6	-0.406 3	-0.001 3
IMF <sub>7</sub>	0.201 1	0.019 9	0.027 3	0.476 3	-0.613 6	-0.000 5
IMF <sub>8</sub>	0.212 5	0.041 9	0.057 6	0.613 9	-0.597 0	-0.003 8
IMF <sub>9</sub>	0.397 8	0.049 5	0.068 0	0.634 6	-0.694 3	-0.009 7
IMF <sub>10</sub>	0.515 2	0.099 9	0.137 3	0.486 6	-0.510 4	-0.098 1
r	0.881 2	0.501 6	0.689 1	2.694 7	0.282 5	1.518 7

### (二) 聚类

考虑到 EMD 可能对数据进行过度分解, 本文对 IMF 进行聚类, 以便进行后续检验。通过使用  $r$

语言层次聚类包加载数据, 获得如下结果: IMF<sub>6</sub>—IMF<sub>10</sub> 为一类, IMF<sub>2</sub>、IMF<sub>3</sub> 为一类, IMF<sub>1</sub>、IMF<sub>4</sub>、IMF<sub>5</sub> 为一类。其可用于后续层次聚类组合模型

的计算。

当前除层次聚类外广泛使用的是 K-means 聚类,然而,此算法不适合处理波动较大的数据。本文使用的信号波动很大,这导致平均值的计算会受到异常点的严重干扰,而使用 K-medoids 方法可以克服这个问题。通过聚类得出最佳簇数为 5,同时,结合每个 IMF 的平均值,发现 IMF<sub>6</sub> 后每个 IMF 的平均值显著偏离 0,这与通过 K-medoids 聚类获得的聚类一致,即认为前六个 IMF 是高频分量,后四个 IMF 是低频分量。

从图 4 可以看出,趋势价格是油价的主要组成部分,对油价的长期走势具有决定性影响。趋势项目的上升趋势与世界经济的发展同步。这也表明,世界经济的发展水平决定了航空燃油价格的长期趋势。根据表 1 获得的结果,IMF<sub>1</sub>—IMF<sub>6</sub> 在 K-medoids 聚类组合模型的计算中被归为一类,IMF<sub>7</sub>—IMF<sub>10</sub> 被组合为另一个类别。

### (三)自回归移动平均模型

本文选择 7 185 个时间点中最新的 1 085 个(约占总周期数的 15%)作为测试集。评估模型预测有多种标准,例如平均绝对距离(MAD)、平方误差和(SSE)、均方误差(MSE)和均方根误差(RMSE)等。本文使用 MSE 和 RMSE 作为模型评估的标准。

在许多金融交易中,预测时间序列的趋势与预测时间序列值一样重要。时间序列的趋势分为两种情况:上升和下降。如果当前值大于先前的值,将其称为上升趋势;如果当前值小于先前的值,将

其称为下降趋势。表 2 列出了三种模型的预测结果和趋势预测结果。

从表 2 可以看出,使用经验模态分解后预测的价格精度和趋势精度有了较大提升, RMSE 从 1.268 5 降低到 1.075 5,趋势正确率从 27.46% 增加到 45.99%。然而,聚集 IMF 后得到结果的准确性大大降低甚至低于 ARMA 模型。特别是层次聚类之后模型的 RMSE 增加到 1.392 9,低于 ARMA 的预测精度。在 K-medoids 聚类之后, RMSE 相较于层次聚类略有下降。在趋势预测中,两种聚类方法的改进和下降并不明显,与单一 ARMA 模型没有太大差异。

表 2 评估模型预测

模型	MSE	RMSE	趋势 准确率/%
ARMA	1.609 3	1.268 5	27.46
EMD-ARMA	1.156 8	1.075 5	45.99
层次聚类-EMD-AEMA	1.940 1	1.392 9	23.04
K-medoids 聚类-EMD-AEMA	1.848 3	1.359 5	30.69

但是,在长期价格和趋势的预测上这些方法都还有一定的局限性。预测时间越长,控制由重要事件的低频分布引起的误差就越困难。在长期预测中,无论使用哪种模型对趋势以及数值的预测精度均不佳,EMD-ARMA 模型更适合中短期的预测。从表 3 可以明显看出,EMD-ARMA 模型在预测精度方面的优势。总而言之,经验模态分解给时间序列预测带来了很大的变化,可以在一定程度上提高模型的预测准确度,也可以提高趋势预测的准确性。

表 3 各预测模型结果对比

时间	ARMA		EMD-ARMA		层次聚类		K-medoids 聚类	
	RMSE	MSE	RMSE	MSE	RMSE	MSE	RMSE	MSE
6 个月	0.654 69	0.809 1	0.392 1	0.626 21	0.682 9	0.826	0.597 5	0.773 0
12 个月	1.231 57	0.981 4	0.766 1	0.769 86	1.327 6	1.152	1.308 4	1.143 9

## 三、结论与建议

### (一)结论

在实际的金融市场价格预测中,对价格数量的分析和准确预测具有重要意义。本文将 EMD 和 ARMA 模型应用于航空燃油价格预测,数据的实证分析结果与针对过度分解而进行的层次聚类和 K-medoids 聚类分析结果表明:经验模态分解可用

于分离时间序列中隐含的高频波动分量和低频趋势分量,这种数据预处理降低了信号序列的非平稳性,并为 ARMA 模型构建做了充足的前期准备。新算法在一定程度上保证了局部预测的准确度,同时在一定程度提升了整体预测的精度。研究结果显示,在使用 EMD 预先分解数据后,航空燃油价格的预测精度得到一定程度的提升,作为参考值之一的均方根误差从未使用 EMD 分解的 0.809 1 下降到 0.626 21,同时趋势预测的准确率也从原先的

27.46%提高到45.99%,价格预测模型的准确度得到一定程度的提高。因此,基于经验模态分解和ARMA的新算法在航空燃油价格预测中具有一定的应用价值。传统的计量经济学模型在提高精度上具有诸多局限性,无法充分挖掘出数据中所隐藏的信息。例如,本文在对IMF6、IMF8、IMF9的预测中发现这三组数据均为白噪,但IMF8、IMF9的均值却不为0,这三组数据理论上无法使用ARMA模型,只能进行人工模拟,这势必会产生一定的误差。而对于现有的支持向量机、神经网络、决策树等机器学习模型而言,这种数据并不会不适用于预测。基于此,本文认为,在传统模型的基础上配合机器学习模型可能会在一定程度上提升预测的精度,但值得注意的是,EMD-ARMA模型本身在计算上已经相当复杂,倘若结合相应的机器学习模型,需要科学编制循环算法以降低计算难度。

## (二)建议

随着国际局势的剧烈变动,各种不确定风险日益增多,商品期货价格波动更加剧烈,基于数据本身分析预测的结果的准确性会大打折扣。基于上述结论,结合相关实证分析,本文提出以下几点建议:

1. 国内能源企业要对外积极开展并参与国际能源合作,通过兼并、收购等方式加大能源供给,取得一定的对能源定价的话语权并建立能源价格稳定机制。企业要开源节流,加强对总消耗量的控制,提高能源使用效率,彻底改变能源过度消耗的大环境,促进产业结构和能源消费结构的双重优化,促进能源梯级利用、能源资源的循环利用和综合利用;加快节能型社会建设,降低社会能源使用成本。

2. 当油价上涨时,航空公司可以提前适量买入航空燃油期货,通过期货合同规避价格上涨带来的成本上升<sup>[7]</sup>。对于投资者而言,可通过期权组合策略进行套利,因为价格的波动率对于到期时间不同的期权合约价格的影响是不同的:对于到期日近的合约,波动率的影响要大于到期日远的合约。随着

波动率的变化,不同月份的期权合约的价格会出现变化,因此,可通过期权组合策略,如风险较小的蝶式组合进行套利<sup>[8]</sup>。

3. 政府相关部门需要加强监管,防止出现因市场波动而产生的违法套利等破坏市场秩序的行为,充分发挥政策调控和市场自我控制在资源配置中的决定性作用;遵循市场经济规律和能源产业发展规律,突出市场参与者在促进能源革命中的作用。要更好地发挥政府的作用,建设服务型政府,加强基本制度建设,完善法律法规,维护市场秩序,实现能源治理方式现代化;同时加快经济结构调整,增加技术投入,研发新能源,鼓励如生物煤油等清洁可再生能源等的使用,逐渐降低相关企业如航空公司对航空燃油的依赖。

## 参考文献:

- [1] 崔冰波,陈熙源,宋锐. EMD 阈值滤波在光纤陀螺漂移信号去噪中的应用[J]. 光学学报, 2015(2): 53-58
- [2] 刘海江,刘世高,李敏. 换挡加速度信号的 EMD 和小波阈值降噪方法[J]. 噪声与振动控制, 2018(2): 198-203
- [3] Anderberg M R. Cluster Analysis for Applications[M]. New York: Academic Press, 1973:181
- [4] 马箐,谢娟英. 基于粒计算的 K-medoids 聚类算法[J]. 计算机应用, 2012(7): 1973-1977
- [5] Tal Galili. Dendextend: An R Package for Visualizing, Adjusting and Comparing Trees of Hierarchical Clustering[J]. Bioinformatics, 2015, 31(22): 3718-3720
- [6] Feng Ding, Yang Shi, Tongwen Chen. Performance Analysis of Estimation Algorithms of Nonstationary Arma Processes[J]. IEEE Transactions on Signal Processing, 2006, 54(3): 1041-1053
- [7] 陆岷峰,李蔚. 金融供给侧改革中商业银行的担当与实施路径[J]. 福建金融, 2019(6): 4-12
- [8] 陆岷峰,马经纬,汪祖刚. 金融科技背景下普惠金融基本矛盾图谱与解决路径研究[J]. 金融理论与实践, 2019(8): 1-7

(责任编辑:李海霞)