

基于 EMD-ES-LSTM 组合模型的 货运量预测

聶志峰

(华北电力大学经济与管理学院, 北京 102206)

摘要: 货运物流在构建国内大循环为主体和国内国际双循环相互促进的新发展格局中有着重要支撑作用。科学合理预测货物周转量,既能反映交通运输行业的运行状况,也可以从货运量角度,判断未来宏观经济变化,保障国民经济高质量发展。以全国货物周转量为研究对象,充分考虑货运量序列的非线性、波动性和周期性等特性,提出一种基于经验模态分解-指数平滑-长短期记忆网络(EMD-ES-LSTM)的预测方法。首先,采用经验模态分解法对波动性大的周转量序列进行频率处理,分解出特性不同的分量,优化模型输入。其次,利用指数平滑法和长短期记忆网络对不同特性的分量进行拟合预测,进一步提高预测精度。通过实际数据来验证模型的有效性。结果表明,相较于单一模型和对比的组合模型,EMD-ES-LSTM 方法的平均绝对百分比误差(MAPE)为 4.04%,预测性能较好,有助于为研判未来交通运输行业和宏观经济的发展,提供方法支持。

关键词: 货运量预测; EMD; ES; LSTM; 深度学习

DOI:10.12323/j.issn.1673-0542.2023.01.007

货运量是衡量一个国家物流综合实力和经济发展的重要指标。准确地对货运量进行预测,既能明确未来货运发展趋势,也可以反映经济运行态势,对于宏观经济分析具有指导性的作用^[1]。严雪晴建立 GM(1, 1) 模型对 2018—2022 年广东省货运总量及其构成进行预测,以期探讨广东省货运总量及构成的发展趋势^[2]。黎可馨采用自回归差分移动平均模型(Autoregressive Integrated Moving Average, ARIMA)对货物周转量进行预测^[3]。耿立艳等使用最小二乘支持向量机对铁路货物周转量月度数据进行预测^[4]。张冠东等采用多维的长短期记忆网络(Long Short Term Memory, LSTM)模型对铁路、公路和民航的货运量数据进行预测^[5]。程肇兰等利用 LSTM 模型分别对各月

和每日的货运发送量进行预测^[6]。

在单一货运预测方法的基础上,众多学者采用组合预测模型,以提高货运量预测的精确度。徐玉萍等针对货运量数据的线性和非线性因素,在乘积季节模型的基础上,引入 LSTM 模型,构建组合预测模型,以提高预测精度^[7]。张仙等建立融合 SARIMA 模型和粒子群优化算法优化的极限学习机模型,以预测周期性和波动性较大的铁路货运量^[8]。张英贵等提出一种基于指数平滑-遗传算法-反向传播(ES-GA-BP)神经网络的货运量预测方法,研究波动较大的中欧班列货运量预测问题^[9]。刘辉使用灰色关联分析法筛出影响铁路货物周转量的主要因素,建立 BP 神经网络,对江苏省铁路货物周转量进行预测^[10]。

由于货物周转量的影响因素复

杂多变,容易受到主观的影响,以及部分因素是难以量化的。因此针对我国货物周转量的非平稳性和影响因素的难以合理提取,本文使用经验模态分解(Empirical Mode Decomposition, EMD)对原始数据进行处理,而后使用指数平滑法(Exponential Smoothing, ES)和 LSTM 对高频分量进行组合预测,从而构建基于 EMD-ES-LSTM 组合预测模型,克服原始序列波动大,导致单一预测模型精度不足的局限性。并与基准模型进行对比,有效地提高预测精度,从而验证模型的有效性。

1 研究方法

1.1 经验模态分解

经验模态分解不依赖于特定的基函数,因此其适用于对非线性、非平

稳信号进行处理与分析。它克服了基函数需要通过小波分解进行设置的问题，具有一定的适应性。其从不同频率的时间序列中提取成分，根据数据的时间尺度特性，将复杂数据分解成有限的各频率分量，并将频率从高频到低频的顺序依次排列。EMD 分解是将一个信号分解为 n 个固有模态函数 (Intrinsic Mode Function, IMF) 和一个残差 (residual)。原始信号 $x(t)$ 分解，公式如下。

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

1.2 长短期记忆网络

LSTM 是一种特殊的递归神经网络，引入了门机制来控制信息传输的路径，具有学习长期依赖关系的能力，克服了梯度消失问题。LSTM 中记忆单元可以存储不同时间段的信息，并自动捕捉输入数据和输出数据之间的关联性。LSTM 网络中的重要公式如下：

$$f_t = \delta(W_f^T \times h_{t-1} + U_f^T \times x_t + b_f) \quad (2)$$

$$i_t = \delta(W_i^T \times h_{t-1} + U_i^T \times x_t + b_i) \quad (3)$$

$$c_t = \tanh(W_c^T \times h_{t-1} + U_c^T \times x_t + b_c) \quad (4)$$

$$c_t = f_t \times c_{t-1} + i_t \times c_t \quad (5)$$

$$h_t = o_t \times \tanh(c_t) \quad (6)$$

$$o_t = \delta(W_o^T \times h_{t-1} + U_o^T \times x_t + b_o) \quad (7)$$

式中， f_t 、 i_t 和 c_t 分别是时刻 t 的遗忘门、输入门和输出门的输出； c_t 和 c_{t-1} 分别是 t 时刻和 $t-1$ 时刻的单元状态； t 时刻和 $t-1$ 时刻的单元输入分别是 h_{t-1} 和 x_t 。

2 建模流程和评价指标

考虑货物周转量的非平稳性，采用 EMD 方法分解为不同频率的 IMF 分量，对于高频分量 IMF_1 ，选择 ES 方法、朴素贝叶斯 (Naive Bayes, NB)、ARIMA 和 LSTM 方法进行预测。其余分量采用 LSTM 进行预测，将所有预测结果加和为最终输出，从而构建 EMD-ES-LSTM 组合预测模

型，建模流程如图 1 所示。

为客观评估模型的有效性，本文选择平均绝对百分比误差 (Mean Absolute Percent Error, 简称为 MAPE) 和均方根误差 (Root Mean Square Error, 简称为 RMSE) 作为评价指标，计算公式为：

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (8)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

其中， n 表示样本数量， y_i 表示样本 i 的真实值， \hat{y}_i 表示样本 i 的预测值。

3 实证分析

3.1 EMD 分解

从国家统计局获取我国 2010 年 1 月—2022 年 6 月的货物周转量当期数据。其中初始样本量共计 150 个。选用 2010 年 1 月—2021 年 6 月的数据为训练集、2021 年 6 月—2022 年 7 月的数据为测试集。货物周转量 EMD 分解，如图 2 所示。

本文根据时间尺度将货物周转量分解为频率不同的 4 个 IMF 分量和 1 个残余分量。IMF 分量代表的在同一时间内不同频率和增幅序列，其中 IMF 分量根据频率由大到小排列。从




图 2 货物周转量 EMD 分解图

IMF_4 分量的变化趋势上可以发现，货物周转量数据整体呈现向上增长的趋势。

3.2 结果分析

为考察 EMD 分解前后预测结果精度的变化，在组合预测模型的基础上，增加单一的 LSTM 模型作为对比模型，各个模型的预测结果，如图 3 所示。各模型的误差效果对比情况，如表 1 所示。

由图 4 和表 1 可知，在 2021 年 6 月至 2022 年 6 月的货运量测试集中，单一的 LSTM 模型的误差最大，其中 MAPE 为 7.64%，RMSE 为 1666。本文所建的 EMD-ES-LSTM 模型

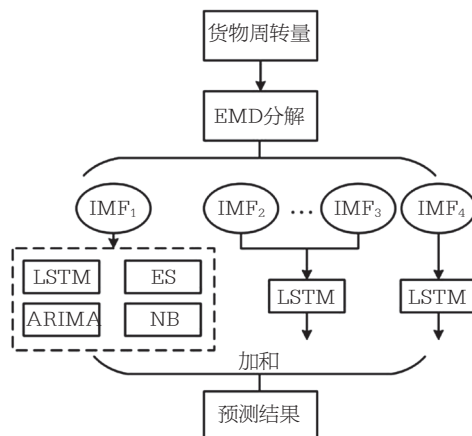


图 1 基于 EMD-ES-LSTM 模型的建模流程

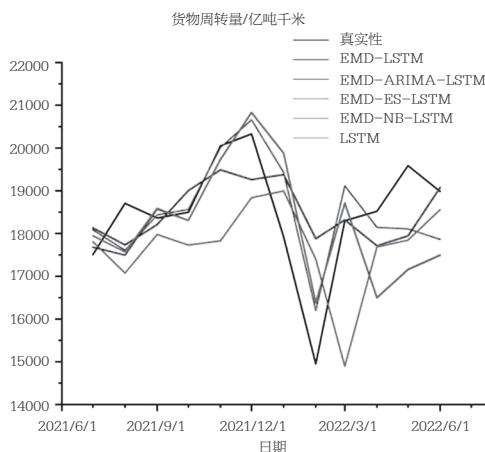


图3 模型预测结果




图4 预测性能对比

表1 模型评价效果对比

模型	MAPE	RMSE
EMD-LSTM	5.12%	1194
EMD-ARIMA-LSTM	5.63%	1296
EMD-ES-LSTM	4.04%	901
EMD-NB-LSTM	5.73%	1298
LSTM	7.64%	1666

的误差最小，其中MAPE为4.04%，RMSE为901。EMD-LSTM模型的误差其次，MAPE和RMSE分别为5.12%，1194。这表明与单一预测模型相比，组合预测模型的预测效果更优。相比于其他组合模型，本文所提的EMD-ES-LSTM的预测性能较好，从而证明所提组合模型预测的有效性，可为货运量预测提供一种新的思路。

4 结语

以货物周转量月度数据为研究对象，考虑货运量数据的非线性和波动性的特点，构建一种基于EMD-ES-LSTM的预测模型，该方法具有较高的货运量预测精度。首先，通过EMD将原始序列转化为不同频率的分量；其次，针对频率最高的分量选择ES进行预测，其余分量的预测模型为LSTM方法；最后，将各个子分量加权汇总为最终的预测结果，并使用两种误差评价指标进行分析与评估。结果发现，使用EMD-ES-LSTM组合的货运量预测模型精度优于单一的LSTM模型，也优于包括ARIMA和

NB模型在内的组合模型。

参考文献

- [1] 高敏雪,黎煜坤,李静萍.耦合与解耦视角下中国货物运输与经济增长的关系研究[J].经济理论与经济管理,2019(5):75-87.
 - [2] 严雪晴.基于灰色预测模型的广东省货运总量预测研究[J].数学的实践与认识,2020,50(14):294-302.
 - [3] 黎可馨.基于季节性ARIMA模型的中国货物周转量短期预测[J].现代信息技术,2022,6(3):141-144.
 - [4] 耿立艳,张占福.铁路货物周转量的LSSVM智能组合预测法[J].统计与决策,2019,35(24):77-80.
 - [5] 张冠东,杨琛.基于多维长短时记忆网络的货运量预测[J].统计与决策,2022,38(12):180-183.
 - [6] 程肇兰,张小强,梁越.基于LSTM网络的铁路货运量预测[J].铁道学报,2020,42(11):15-21.
 - [7] 徐玉萍,邓俊翔,蒋泽华.基于组合预测模型的铁路货运量预测研究[J].铁道科学与工程学报,2021,18(1):243-249.
 - [8] 张仙,戴家佳,余奇迪.基于SARIMA-PSO-ELM组合模型的我国铁路货运量预测[J].数理统计与管理,2022,41(3):394-401.
 - [9] 张英贵,杨蕙瑜,雷定猷.基于组合输入ES-GA-BP的中欧班列货运量预测[J].深圳大学学报(理工版),2022,39(2):168-176.
 - [10] 刘辉.基于BP神经网络的江西省铁路货物周转量预测[J].齐齐哈尔大学学报(自然科学版),2014,30(1):50-53.
- 作者简介: 聶志峰(1998—),男,山西朔州人,硕士研究生。研究方向:供应链管理。