

控制与决策

Control and Decision

基于EEMD-LMD-LSTM-LEC深度学习模型的短时物流需求预测

冉茂亮, 陈彦如, 杨新彪

引用本文:

冉茂亮, 陈彦如, 杨新彪. 基于EEMD-LMD-LSTM-LEC深度学习模型的短时物流需求预测[J]. *控制与决策*, 2022, 37(10): 2513-2523.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.0413>

您可能感兴趣的其他文章

Articles you may be interested in

[一种并行LSTM-FCN模型在船舶航迹预测中的应用](#)

Parallel LSTM-FCN model applied to vessel trajectory prediction

控制与决策. 2022, 37(8): 1955-1961 <https://doi.org/10.13195/j.kzyjc.2020.1795>

[基于卷积长短时记忆神经网络的城市轨道交通短时客流预测](#)

Metro short-term traffic flow prediction with ConvLSTM

控制与决策. 2021, 36(11): 2760-2770 <https://doi.org/10.13195/j.kzyjc.2020.0501>

[迁移学习引导的变源域长短时记忆网络建筑负荷预测](#)

Load forecasting of buildings using LSTM based on transfer learning with variable source domain

控制与决策. 2021, 36(10): 2328-2338 <https://doi.org/10.13195/j.kzyjc.2020.0215>

[基于FWADE-ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925-932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

[基于FWADE-ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925-932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

基于EEMD-LMD-LSTM-LEC深度学习模型的 短时物流需求预测

冉茂亮¹, 陈彦如^{1,2†}, 杨新彪¹

(1. 西南交通大学 经济管理学院, 成都 610031; 2. 服务科学与创新四川省重点实验室, 成都 610031)

摘要: 短时物流需求预测是智慧物流系统的重要组成部分. 由于短时物流需求数据具有非平稳性、强随机性、局部突变、非线性等特征, 精确预测较为困难. 对此, 考虑集成经验模态分解 (EEMD)、局部均值分解 (LMD)、长短期记忆网络 (LSTM) 以及考虑局部误差校正 (LEC), 提出用于短时物流需求预测的 EEMD-LMD-LSTM-LEC 深度学习模型. 该预测模型分为两个阶段: 第 1 阶段基于特征分解和特征提取, 构建 EEMD-LMD-LSTM 模型, 以降低非线性的原始短时物流需求不平稳及随机变化导致的预测误差; 第 2 阶段构建局部误差校正模型, 用于校正第 1 阶段的预测结果, 以减少短时物流需求的局部突变带来的预测误差. 实验结果表明, EEMD-LMD-LSTM-LEC 短时物流需求预测模型在均方根误差、绝对误差均值、绝对误差百分比和校正决定系数方面, 均优于其他 11 种对比模型, 其中包括: 数理统计模型——ARIMA; 浅层机器学习模型——支持向量回归和 BP 神经网络; 深度学习模型——LSTM 和卷积神经网络; 组合模型——深度置信网络-LSTM、经验模态分解 (EMD)-LSTM、EEMD-LSTM、LMD-LSTM、EMD-LMD-LSTM 和 EEMD-LMD-LSTM.

关键词: 短时物流需求; 集成经验模态分解; 局部均值分解; 长短期记忆网络; 局部误差校正; 预测

中图分类号: TP181 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2021.0413

引用格式: 冉茂亮, 陈彦如, 杨新彪. 基于 EEMD-LMD-LSTM-LEC 深度学习模型的短时物流需求预测 [J]. 控制与决策, 2022, 37(10): 2513-2523.

Short-term logistics demand forecasting based on EEMD-LMD-LSTM-LEC deep learning model

RAN Mao-liang¹, CHEN Yan-ru^{1,2†}, YANG Xin-biao¹

(1. School of Economics and Management, Southwest Jiaotong University, Chengdu 610031, China; 2. Key Laboratory of Service Science and Innovation of Sichuan Province, Chengdu 610031, China)

Abstract: Short-term logistics demand forecasting is one of critical components of the smart logistics system. As short-term logistics demand data is non-stationary, nonlinear series with strong randomness and singular points, it is difficult to accurately predict short-term logistics demand. Therefore, this paper proposes EEMD-LMD-LSTM-LEC deep learning model for short-term logistics demand forecasting, based on ensemble empirical mode decomposition (EEMD), local mean decomposition (LMD), and long and short-term memory (LSTM) neural networks while considering local error correction (LEC). The proposed model is divided into two stages. In the first stage, the EEMD-LMD-LSTM model is constructed based on feature decomposition and feature extraction, to reduce the error caused by non-linearity, non-stationarity and randomness of short-term logistics demand. In the second stage, a local error correction model is constructed to adjust the prediction results in the first stage for reducing the error caused by the singular points of short-term logistics demand. The results show that the proposed EEMD-LMD-LSTM-LEC model works better than other eleven models, in terms of root mean square errors, mean absolute errors, mean absolute percentage errors and the adjusted coefficient of determination, including the mathematical statistics model — ARIMA, shallow machine learning models — support vector regression and the BP neural network, deep learning models — LSTM and the convolutional neural network, combined models — the deep belief network-LSTM, empirical mode decomposition (EMD)-LSTM, EEMD-LSTM, LMD-LSTM, EMD-LMD-LSTM and EEMD-LMD-LSTM.

Keywords: short-term logistics demand; ensemble empirical mode decomposition; local mean decomposition; long and short time memory neural network; local error correction; forecasting

收稿日期: 2021-03-11; 录用日期: 2021-07-19.

基金项目: 国家重点研发计划项目 (2018YFB1601402); 国家自然科学基金项目 (71771190).

责任编辑: 侯忠生.

†通讯作者. E-mail: chenyanru@swjtu.edu.cn.

0 引言

智慧物流的本质是利用信息资源和智力资源更好地实现物流系统供需多维度高效率的精准匹配. 相对于物流供给, 物流需求更具驱动性, 因此, 如何准确地捕捉和预测物流需求不同层面、不同时间维度的变化特征, 是发展智慧物流系统的核心和关键. 尤其是微观层面的短时物流需求预测, 不仅能提高微观层面物流供给的及时性、准确性和经济性, 也能揭示物流需求宏观和长时段层面变化规律, 为各层面物流管理提供决策支持.

关于物流需求预测的研究主要集中在宏观或中观层面的长时段物流需求上, 目前已有较为丰富的研究成果. 由于长时段物流需求的统计时间间隔通常以年为单位, 其变化趋势相对平稳. 然而, 短时物流需求由于影响因素多、作用机理复杂, 呈现出非平稳性、强随机性、局部突变等特征, 已有方法直接用于短时物流需求预测, 很难保证预测精度.

由于短时物流需求是一类非平稳的时序数据, 考虑到深度学习方法——长短期记忆网络(long short-term memory, LSTM)在时序建模问题上具有长时记忆优势^[1-2](能够解决长序列训练过程中存在的梯度消失和梯度爆炸的问题), 同时, 经验模态分解(empirical mode decomposition, EMD)在处理非平稳数据的优势^[3](它可以对信号进行分解, 实现非平稳数据的平稳化处理), 但EMD方法仍存在局限性, 主要问题是模态混叠和端点效应^[4]. 对此, 文献[4]提出了集成经验模态分解(ensemble empirical mode decomposition, EEMD)方法来解决模态混叠问题. 本文拟结合LSTM与EEMD对短时物流需求进行预测. 然而, EEMD只能消除EMD中的模态混叠问题, 端点效应问题仍无法妥善解决, 对此, 本文同时引入局部均值分解(local mean decomposition, LMD). 该方法可以解决原始信号中的信息难以提取等问题^[5]以及EEMD中存在的端点效应等问题^[6]. 此外, 短时物流需求还具有局部突变特征, 增加了预测难度, 对此, 本文提出采用局部误差校正(local error correct, LEC)来解决该问题.

与已有研究相比, 本文的主要贡献如下:

1) 研究对象不同. 目前, 物流需求主要研究的对象是以年为统计单位的区域物流量, 而本文的研究对象是以12h为统计单位的短时物流需求.

2) 数据特征不同. 目前, 国内外研究中物流需求预测数据的趋势较为平稳且周期性明显, 而本文研究数据呈现非平稳性、强随机性等特征, 已有的机器学

习、深度学习等模型难以捕捉到数据潜在特征.

3) 研究方法不同. 区别于以往的传统统计学方法和机器学习等方法, 本文从特征分解和特征提取两个角度出发, 首先提出EEMD-LMD-LSTM模型, 解决非线性的原始需求不平稳而导致直接预测误差较大以及预测滞后性的问题; 其次设计LEC方法, 解决EEMD-LMD-LSTM模型预测结果在突变处预测误差大的问题, 再次提升了模型的预测精确度.

1 研究现状

1.1 物流需求预测研究现状

目前, 物流需求预测方法主要分为以下4类.

1) 数理统计模型. 代表性的方法有: 灰色预测(grey model, GM)^[7]、指数平滑方法^[8]、ARIMA^[9]模型、多元线性回归模型^[10-11]. 数理统计模型主要以统计学为基础, 各变量之间关系的可解释性较强, 但其模型假设较为简单, 对于随机性强、非线性数据预测精度不高.

2) 浅层机器学习模型. 代表性的方法有: BP神经网络^[12-13]、径向基神经网络^[14]和支持向量机(support vector machine, SVM)及其改进型^[15-17]. 浅层机器学习模型能够对物流需求的非线性规律进行有效捕捉, 提升了预测精度, 但其特征学习能力有限, 其泛化能力受到一定制约.

3) 深度学习模型. 代表性的方法为长短期记忆神经网络^[1]. 深度学习模型因具有更深层次的结构, 且强调对特征的学习, 能较为准确地描述输入与输出的复杂关联, 对时序数据的预测效果通常优于数理统计模型及支持向量机等, 且易于实现, 但其对于具有强随机性的非平稳数据预测精度仍有待提高.

4) 基于以上两个或多个方法的组合预测模型, 如改进的GM(1, 1)模型和BP神经网络模型的组合^[18]. 组合预测模型能够在预测中发挥每个模型各自的优势, 从而提高预测精度.

1.2 数据分解研究现状

1.2.1 EEMD研究现状

EEMD是Wu等^[4]在2009年提出用于解决模态混叠问题的一种噪声辅助数据分析算法. 作为一种高效的数据分解算法, EEMD模型被广泛应用于国内外研究中. 文献[19]基于EEMD模型对金融时间序列进行预测, 通过EEMD对数据分解以降低时间序列的复杂度. 文献[20]通过EEMD将数据分解成高、中、低频率的数据, 构建了基于EEMD的分频混合模型并用于金融时间序列预测. 文献[21]结合EEMD模型和逆云模型获得的信号特征值, 提出了一种齿轮

箱复合故障特征提取方法。

1.2.2 LMD 研究现状

LMD 是另一种数据分解的方法, 具有高度的适应性, 它可以任何复杂的非平稳信号分解为多个有物理意义的乘积函数 (product function, PF) 组件^[22], 然后, 将得到的 PF 分量的瞬时频率和幅值进行组合, 得到原始信号的完整信息分布^[23]。

在影响时间序列的外部因素基本不变的情况下, LMD 分解得到的 PF 分量能较好地描述一个或多个影响数据的时间演化规律。因此, LMD 可以为提取数据内部变化规律的相关信息奠定良好的基础。文献[24]使用局部均值分解 (LMD), 解决了风速时间序列的非平稳性和非线性问题。文献[25]将局部均值分解与奇异值分解相结合, 提高了信号降噪效果。文献[26]提出了一种基于局部均值分解和核函数最小二乘支持向量机 (LSSVM) 的短期风速预测新方法, 并通过实验表明, 经 LMD 分解后的数据能有效解释短期风速的波动、周期性和趋势。

1.3 局部误差校正研究现状

预测模型仅反映了输入变量与输出变量的一般规律, 很容易忽视误差值中蕴含的丰富的序列隐藏信息^[27]。因此, 部分学者展开了对误差校正的研究, 构建误差预测模型, 尝试挖掘和分析预测误差序列的内部信息, 并利用误差预测结果对初始预测值进行校正。代表性的误差预测模型有 GM(1, 1)^[27]、线性

回归^[28]、ARIMA^[29] 等误差预测模型。文献[30]提出了一种基于风速局部爬坡 (LR) 误差校正的方法来改善预测风速的滞后性。文献[31]采用局部动态模拟 (LDA) 方法定位模拟点, 修正数值预报模型预测误差。

综上所述, 国内外学者在物流需求预测方面已有较多的分析, 研究成果具有重要的参考价值, 但仍存在一定的局限。比如, 物流需求预测上的研究对象主要是以年为统计单位的区域物流量, 数据变化趋势相对平稳, 而缺乏对具有非平稳、强随机性、局部突变等特征的短时物流需求的研究。已有研究方法直接用于短时物流需求预测时, 精度难以保证。对此, 本文提出一种用于短时物流需求预测的 EEMD-LMD-LSTM-LEC 模型。其中: 将 EEMD 与 LMD 结合, 通过信号分解深入挖掘数据的特征, 能够减少短时物流需求的非平稳性及强随机性带来的预测误差, 并在一定程度上避免 EMD 带来的模态混叠和端点效应问题; 同时, 采用 LSTM 对 EEMD 和 LMD 的信号分解结果进行并行处理, 能够充分发挥 LSTM 的长时记忆优势。此外, 通过构建 LEC 模型对 LSTM 的预测结果进行局部误差校正, 通过挖掘误差值中的隐藏信息和变量的痕迹解决短时物流需求的局部突变问题。

2 EEMD-LMD-LSTM-LEC 预测模型构建

EEMD-LMD-LSTM-LEC 预测模型主要分为两个阶段: EEMD-LMD-LSTM 模型和 LEC 模型。其预测模型框架如图 1 所示。

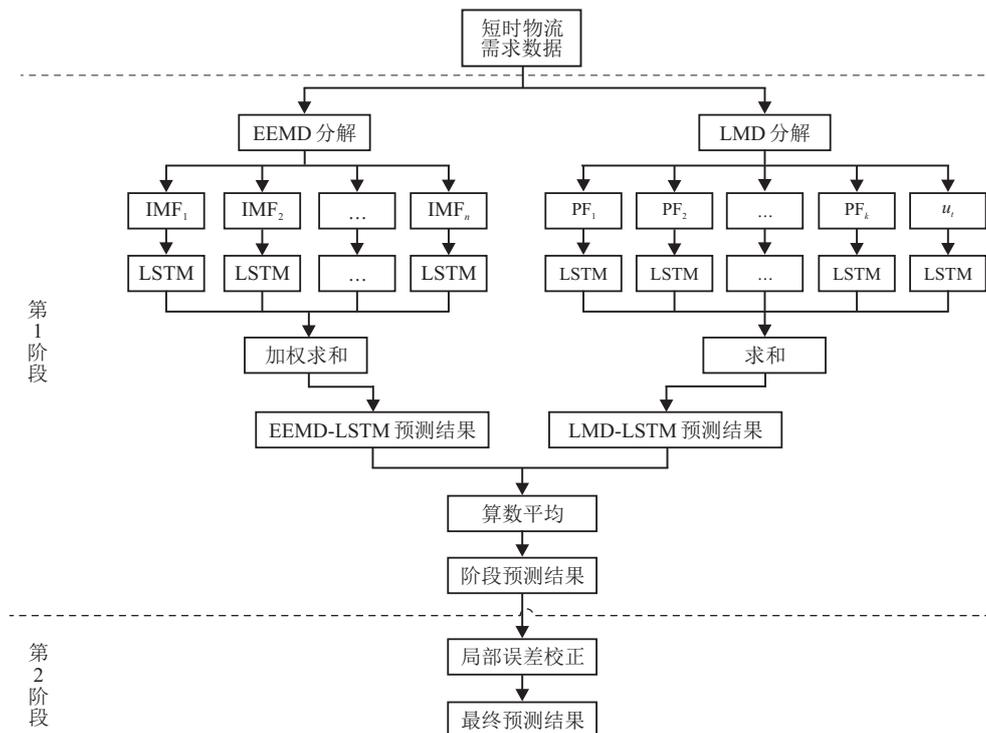


图 1 EEMD-LMD-LSTM-LEC 预测模型框架

2.1 第1阶段模型构建

本阶段首先对短时物流需求原始数据进行EEMD和LMD分解,利用两者的互补性,既降低了EEMD中显著的端点效应,又解决了LMD的过度平滑等问题对预测性能的影响.分解的信号再通过时间序列预测性能强的LSTM进行预测.第1阶段的EEMD-LMD-LSTM预测模型的基本流程如下.

step 1: 数据分解.将短时物流需求原始数据分别进行EEMD分解与LMD分解,得到 n 个本征模态函数(intrinsic mode function, IMF)分量以及 k 个PF分量和残差分量.

step 2: LSTM预测.使用LSTM预测模型分别对 n 个IMF分量、 k 个PF分量和残差分量进行预测.

step 3: 将 n 个IMF分量预测结果加权求和,权重取各IMF分量的pearson相关性系数,得到EEMD-LSTM的预测结果;将 k 个PF分量和残差分量预测结果进行求和,得到LMD-LSTM的预测结果.

step 4: 最终预测值的获得.对上述两种预测结果取算术平均数,作为第1阶段的最终预测值.

2.1.1 短时物流需求数据的EEMD分解

由于短时物流需求数据具有非平稳性及强随机性特征,本模型首先对其进行EEMD分解.

假设 $X = x(1), x(2), \dots, x(t)$ 为预处理后的短时物流需求序列,其中 $x(t)$ 为时刻 t 的短时物流需求量.对该数据进行EEMD分解的主要步骤^[32]如下.

1) 对物流需求量加入 m 种高斯白噪声,得到有噪声伪信号, m 通常取1000,即

$$y_j(t) = x(t) + g_j(t), \quad j = 1, 2, \dots, m. \quad (1)$$

其中: $y_j(t)$ 表示时刻 t 第 j 个有噪声伪信号, $g_j(t)$ 表示时刻 t 第 j 种高斯白噪声.

2) 对加入高斯白噪声的短时物流需求数据(即有噪声伪信号)进行EMD分解,得到 n 个IMF分量和残差,即

$$y_j(t) = \sum_{i=1}^n \text{imf}_{ij}(t) + r_j(t), \quad j = 1, 2, \dots, m. \quad (2)$$

其中: $\text{imf}_{ij}(t)$ 表示对 $y_j(t)$ 进行EMD分解得到的第 i 个IMF分量, $r_j(t)$ 表示对 $y_j(t)$ 进行EMD分解的剩余残差.

3) 将 m 种有噪声伪信号经过EMD分解后得到的IMF分量进行平均,得到 n 个IMF分量,即

$$\text{IMF}_i(t) = \frac{\sum_{j=1}^m \text{imf}_{ij}(t)}{m}, \quad i = 1, 2, \dots, n, \quad (3)$$

其中 $\text{IMF}_i(t)$ 表示对时刻 t 的短时物流需求量 $x(t)$ 进

行EEMD分解最终得到的第 i 个IMF分量.此时共有 n 个IMF分量 $\text{IMF}_i(t)$ ($i = 1, 2, \dots, n$)将分别进行下一阶段的LSTM预测.

2.1.2 短时物流需求数据的LMD分解

由于短时物流需求数据在EEMD分解过程中使用的EMD分解方法存在明显的端点效应,本模型在对短时物流需求原始序列进行EEMD分解的同时对该数据进行LMD分解.

LMD是从短时物流需求序列 X 中抽取出纯调频信号和包络信号的迭代算法.纯调频信号与包络信号相乘能够得到PF分量,将PF分量从原始序列 X 中剥离,即可得到剩余信号.将剩余信号继续进行如上步骤,迭代多次,直到最后一个剩余信号为常数或者单调,即可得到原始信号的时频分布.

对时刻 t 的物流需求量 $x(t)$ 进行LMD分解,最终可得到 k 个PF分量和一个剩余分量 $u(t)$,且原始物流需求量 $x(t)$ 能够被这些分量重构,即

$$x(t) = \sum_{i=1}^k \text{PF}_i(t) + u(t). \quad (4)$$

此时得到的 k 个PF分量 $\text{PF}_i(t)$ ($i = 1, 2, \dots, k$)和剩余分量 $u(t)$ 将分别进行下一阶段的LSTM预测.

2.1.3 EEMD与LMD分解信号的LSTM预测

考虑到短时物流需求数据中存在的时序依赖性,本模型使用LSTM对短时物流需求经过EEMD及LMD分解后的信号进行预测.

在数据分解过程中,利用EEMD对短时物流需求数据分解得到 n 个IMF分量和1个残差分量.对于短时物流需求数据,多次实验发现,该残差分量对后续预测精度提升无显著作用,因此,该残差分量忽略不计.以时刻 t 为例,记 $\text{IMF}(t) = \{\text{IMF}_1(t), \text{IMF}_2(t), \dots, \text{IMF}_n(t)\}$.经LMD分解得到 k 个PF分量和残差 $u(t)$,记 $\text{PF}(t) = \{\text{PF}_1(t), \text{PF}_2(t), \dots, \text{PF}_k(t), u(t)\}$.这些信号本质上都是短时物流需求数据 X 在时间序列 $T = 1, 2, \dots, t$ 上分解和提取出来的特征,反映了短时物流需求在时间序列上的变化.为方便后续LSTM计算过程的描述,本文将IMF和PF信号统一记为 $F = \{F_1, F_2, \dots, F_n, \dots, F_{n+k}, F_{n+k+1}\}$.

以信号 F_i ($i = 1, 2, \dots, n+k+1$)为例,其在时刻 t 的特征值记为 f_i^t .当考虑与时刻 t 紧邻的前 q 个统计时段的物流需求特征值对时刻 t 的物流需求特征值影响时,将前 q 个统计时段的物流需求特征值数据集 $\{f_i^{t-q}, \dots, f_i^{t-2}, f_i^{t-1}\}$ 作为LSTM在时刻 t 的输入 Z_i^t .LSTM在时刻 $t-1$ 的输出记为 h_i^{t-1} ,在时刻 $t-1$ 的单元状态记为 C_i^{t-1} ,两者也同时作为LSTM的输

入信息.

时刻 t 的输出值以及单元状态的值分别记为 h_i^t 、 C_i^t ;时刻 t 的输入门、输出门、遗忘门以及单元状态的权重矩阵分别记为 W_e 、 W_o 、 W_f 、 W_c ; b_e 、 b_o 、 b_f 和 b_c 是时刻 $t-1$ 到时刻 t 的输入门、输出门、遗忘门和单元状态的偏置向量; F_i^t 为时刻 t 遗忘门的输出结果; I_i^t 为时刻 t 输入门的输出结果; O_i^t 为时刻 t 输出门的输出结果; \hat{C}_i^t 为时刻 t 的候选单元状态; C_i^t 为时刻 t 的单元状态. 于是, 整个LSTM单元的计算过程如下^[33-34]:

遗忘门

$$F_i^t = \sigma(W_f f_i^t + W_f h_i^{t-1} + b_f); \quad (5)$$

输入门

$$I_i^t = \sigma(W_e f_i^t + W_e h_i^{t-1} + b_e); \quad (6)$$

输出门

$$O_i^t = \sigma(W_o f_i^t + W_o h_i^{t-1} + b_o); \quad (7)$$

候选单元状态

$$\hat{C}_i^t = \tanh(W_c f_i^t + W_c h_i^{t-1} + b_c); \quad (8)$$

单元状态

$$C_i^t = F_i^t C_i^t + I_i^t \tanh(\hat{C}_i^t); \quad (9)$$

单元输出

$$h_i^t = O_i^t \tanh(C_i^t); \quad (10)$$

其中 σ 表示神经网络的激活函数sigmoid.

整个过程中, 短时物流需求数据经分解后提取到的特征值将由3个交互的功能性细胞结构——遗忘门、输入门和输出门进一步筛选和更新. 输出门最后用sigmoid层来过滤单元的状态, 随后将经过tanh层的过滤状态乘以 O_i^t 来获得短时物流需求的输出值 h_i^t ^[35].

2.2 EEMD-LMD-LSTM-LEC短时预测模型构建

当物流需求在短时间内呈现骤然上升或者下降的趋势, 即局部突变时, 预测结果在突变处会产生明显的预测误差, 如图2实线圈所示. 此外, 由于短时物

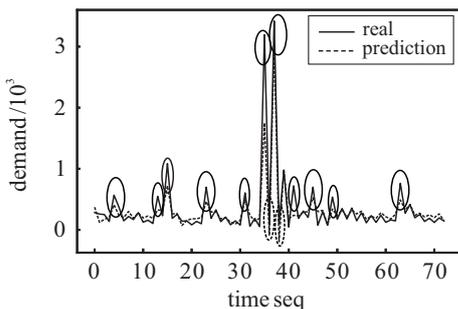


图2 短时物流需求的局部突变

流需求的强随机性, 容易导致预测值出现负值, 产生预测误差, 如图2虚线圈所示.

为了减少突变点和负值点带来的预测误差, 提高预测精度, 本文提出一种局部误差校正方法LEC. 使用该方法对短时物流需求预测的误差值序列进行预测, 进而对第1阶段的预测值进行校正, LEC模型框架如图3所示.

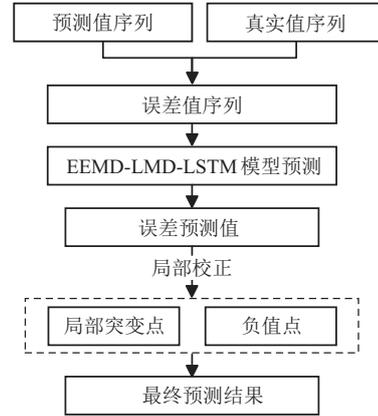


图3 LEC模型框架

第2阶段的LEC模型的基本流程如下.

step 1: 计算第1阶段EEMD-LMD-LSTM模型得到的预测值序列与真实值序列的差值, 得到误差值序列;

step 2: 使用EEMD-LMD-LSTM模型对误差值序列进行预测, 得到误差预测值;

step 3: 确定短时物流需求的突变点和负值点;

step 4: 根据校正规则对第1阶段预测值的突变点及负值点进行局部误差校正, 从而得到最终预测值.

2.2.1 短时物流需求的局部突变的定义

根据物流需求的真实值变化, 可以将变化趋势分为4类: 稳定上升状态、稳定下降状态、骤然上升状态和骤然下降状态. 前两类可称为非局部突变状态, 此时, 时间序列惯性^[36]不会使物流需求的预测值与真实值产生较大误差; 后两类称为局部突变状态, 此时, 物流需求的真实值在前后两个时刻相差较大. 为了对其准确描述, 假设存在前后两个时刻——时刻 t 与时刻 $t-1$, 其对应的短时物流需求差值的绝对值记为 γ , 即

$$\gamma = |x(t) - x(t-1)|. \quad (11)$$

其中: $x(t)$ 代表时刻 t 物流需求量的真实值, $x(t-1)$ 代表时刻 $t-1$ 物流需求量的真实值.

当 γ 满足如下不等式时:

$$\gamma \geq a, \quad (12)$$

可将该状态称为局部突变状态,时刻 t 对应的短时物流需求点称为局部突变点. 阈值 a 的大小随着数据系列的不同而不同,可通过参数寻优获取.

2.2.2 短时物流需求预测局部突变误差的校正

如果时刻 t 对应的物流需求点为局部突变点或负值点,则进行如下校正:

$$x_correct(t) = pred(t) + err(t). \quad (13)$$

其中: $x_correct(t)$ 代表时刻 t 校正后的物流需求预测值; $pred(t)$ 代表时刻 t 的第1阶段物流需求预测值; $err(t)$ 代表时刻 t 的误差预测值,由EEMD-LMD-LSTM模型对误差值序列进行预测所得.

3 实验与结果

3.1 实验数据

为了验证EEMD-LMD-LSTM-LEC预测模型的有效性,本文以某企业自2019年7月1日到2019年12月31日中所有时刻发生的物流需求订单数据作为预测的原始样本集,共计10万条.

考虑到原始数据的离散性以及稀疏值较多,本文选择12h的时间间隔对数据集进行统计. 即:将2019年7月1日00:00~12:00产生的物流需求加总,计为第1条数据;将2019年7月7日12:00~24:00产生的物流需求加总,记为第2条数据;依此类推,统计后12h的短时物流数据为366条. 数据分布如图4所示.

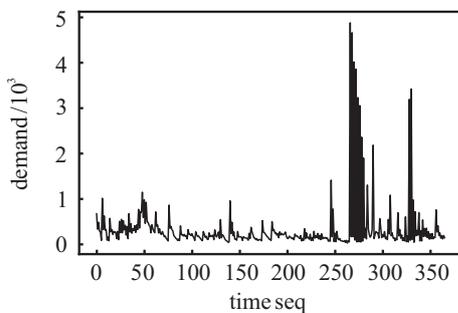


图4 短时物流需求数据分布

由图4可知,短时物流需求数据呈现明显的非平稳性、强随机性、局部突变、非线性等特征.

为了提高算法精度和加速算法的收敛速度,本文使用最大最小归一化对原始数据进行处理,将原始数据值映射到 $[0,1]$ 之间,转换函数如下:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)}. \quad (14)$$

3.2 评价指标

为了确定预测精度,本文分别选取常用的均方根误差(root mean squared error, RMSE)、平均绝对误差(mean absolute error, MAE)、平均绝对百分比误差(mean absolute percentage error, MAPE)、校正决定系

数(adjusted coefficient of determination, R^2)作为评价指标.

3.3 模型参数设置

结合已有研究成果,本文采用前两组物流需求数据来预测第3组的物流需求,即形成两维度输入、一维度输出的预测模型. 此外,为了提高模型预测精度,本文对LSTM模型中的隐层单元数 q 和LEC模型中的突变阈值 a 进行参数寻优.

3.3.1 隐层单元数量 q 的选择

由于不同的隐层单元个数 q 会对预测精度产生影响,本文进行隐层单元数的参数寻优. 考虑到LSTM的原始输入数据为两个维度,结合相关研究经验,分别选择 $q = 4, 8, 16, 32, 64$ 个隐层单元进行实验. 其他参数设置如下:训练迭代次数为3000,初始学习率0.002,测试集占比20%. 隐层单元个数 q 取不同值时的模型预测效果的评价指标值如表1所示.

表1 q 取不同值的评价指标

q 值	评价指标			
	RMSE	MAE	MAPE/%	R^2
4	214.7087	113.2759	53.96238	0.84204
8	247.9043	132.7315	55.92446	0.789421
16	229.1109	128.3042	71.43214	0.820138
32	265.0532	127.9738	54.13262	0.759279
64	245.0637	130.3975	55.59869	0.794219

由表1可知, $q = 4$ 时,4种评价指标最优,表明当隐藏层单元数为4时,预测效果最佳. 因此,本文最终选取4个隐层单元作为LSTM的隐藏层.

3.3.2 突变阈值 a 的选择

由短时物流需求预测误差突变的定义可知,在LEC模型中, a 值的选择对于模型的预测精度至关重要. 一般来说, a 值越小,误差校正的范围越广,最终校正效果会越好. 但另一方面, a 值过小,则本身误差不明显,容易导致校正后的预测值的误差增大,使

表2 a 取不同值的评价指标

a 值	评价指标			
	RMSE	MAE	MAPE/%	R^2
0	124.2726	83.5527	45.4271	0.9471
50	115.9507	78.8723	43.6422	0.9539
100	116.0041	80.8665	46.6868	0.9539
200	117.4620	84.4271	49.6796	0.9527
300	116.1997	82.3631	48.6740	0.9537
400	123.6254	86.0003	51.7097	0.9476
500	123.2463	88.2653	52.2809	0.9480

模型的预测性能反而降低. 因此, 本文分别选取 $a = 0, 50, 100, 200, 300, 400, 500$ 进行测试, 模型预测效果的评价指标如表2所示. 由表2可知, a 的选择对模型的预测精度有明显的影响. 当 $a = 50$ 时, 模型预测精度最高, 其中 R^2 达到了0.9539; 当 $a = 0$ 时, 预测效果最差, 表明此时出现过度校正的问题. 因此, 预测模型

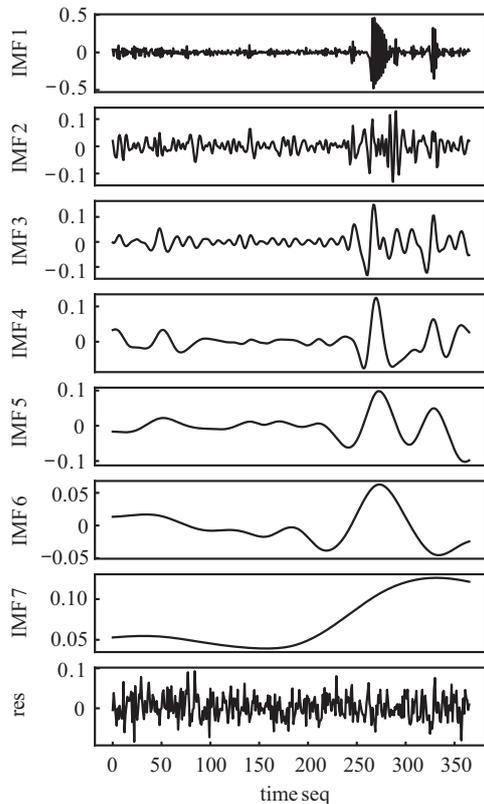
的突变阈值 a 设为50.

3.4 实验结果分析

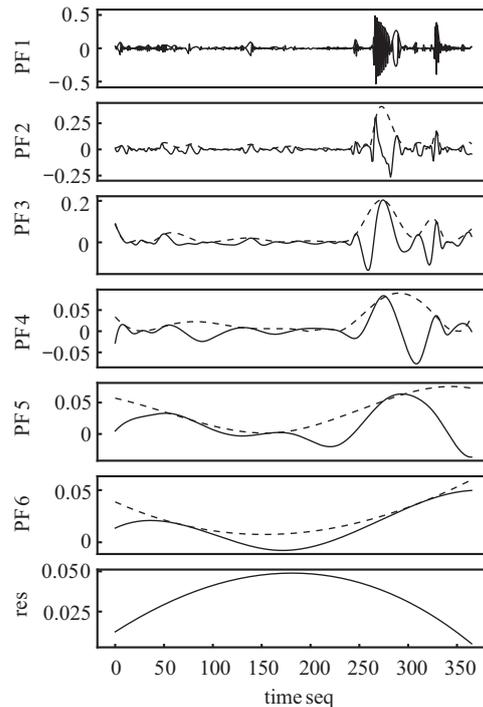
3.4.1 模型预测性能分析

1) EEMD 分解.

对所收集的短时物流需求数据进行EEMD分解, 得到7个IMF分量和1个残差分量, 如图5(a)所示.



(a) EEMD 结果



(b) LMD 结果

图5 短时物流需求数据经EEMD和LMD分解结果

2) LMD 分解.

对短时物流需求数据进行LMD分解后产生了6个PF分量和1个残差分量, 如图5(b)所示. 其中实线部分为PF分量, 虚线部分为相应的包络线.

3) LSTM 预测.

将由EEMD和LMD分解得到的分量分别输入到LSTM中进行预测, 最终得到的第1阶段预测结果如图6所示. 其中模型预测性能指标如下: RMSE

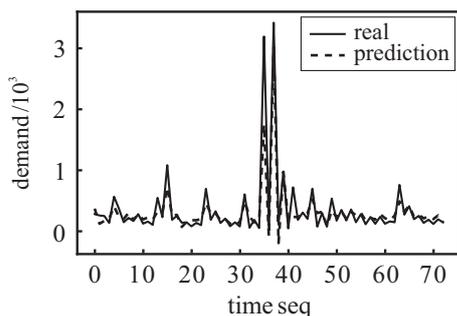


图6 第1阶段的EEMD-LMD-LSTM模型预测效果

为214.709, MAE为113.276, MAPE为53.962%, R^2 为0.842. 由图6可知, 真实值与预测值总体趋势较为一致, 但是, 峰值和突变点处预测性能较差, 因此, 需要进行第2阶段的局部误差校正.

4) LEC 校正.

第2阶段局部误差校正后的预测结果如图7所示. 其中预测性能指标如下: RMSE为115.951, MAE为78.872, MAPE为43.642%, R^2 达到了0.954. 可以

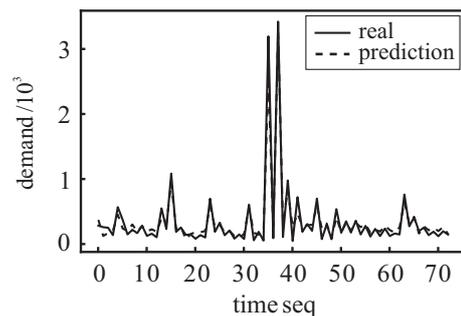


图7 第2阶段的局部误差校正效果

看出,相比于第1阶段,局部误差校正取得了非常好的效果,表现为 R^2 提高了11%,其他指标也有明显的提高.从而表明了EEMD-LMD-LSTM-LEC模型在对短时物流需求预测中的优异性.

3.4.2 模型对比

为了进一步验证本文所提出模型的有效性,分别选取另外11种物流需求预测模型进行对比,包括:1)数理统计模型:ARIMA;2)浅层机器学习模型:支持向量回归(support vector regression, SVR)和BP神经网络(back propagation neural network, BPNN);3)单一深度学习模型:卷积神经网络(convolutional neural

networks, CNN)和LSTM;4)组合预测模型:深度置信网络(deep belief network, DBN)-LSTM、EMD-LSTM、EEMD-LSTM、LMD-LSTM、EMD-LMD-LSTM和EEMD-LMD-LSTM. 预测对比结果如图8所示.由于本文对比算法多达11种,为了直观地显示不同算法预测结果与真实值的差距,本文将对比算法分为4组:1)ARIMA、SVR、BPNN;2)CNN、LSTM、DBN-LSTM;3)EMD-LSTM、EEMD-LSTM、LMD-LSTM;4)EMD-LMD-LSTM、EEMD-LMD-LSTM. 每组数据对应一个子图,同时,在每个子图中都加入本文算法和短时物流需求预测原始数据,以对比预测效果.

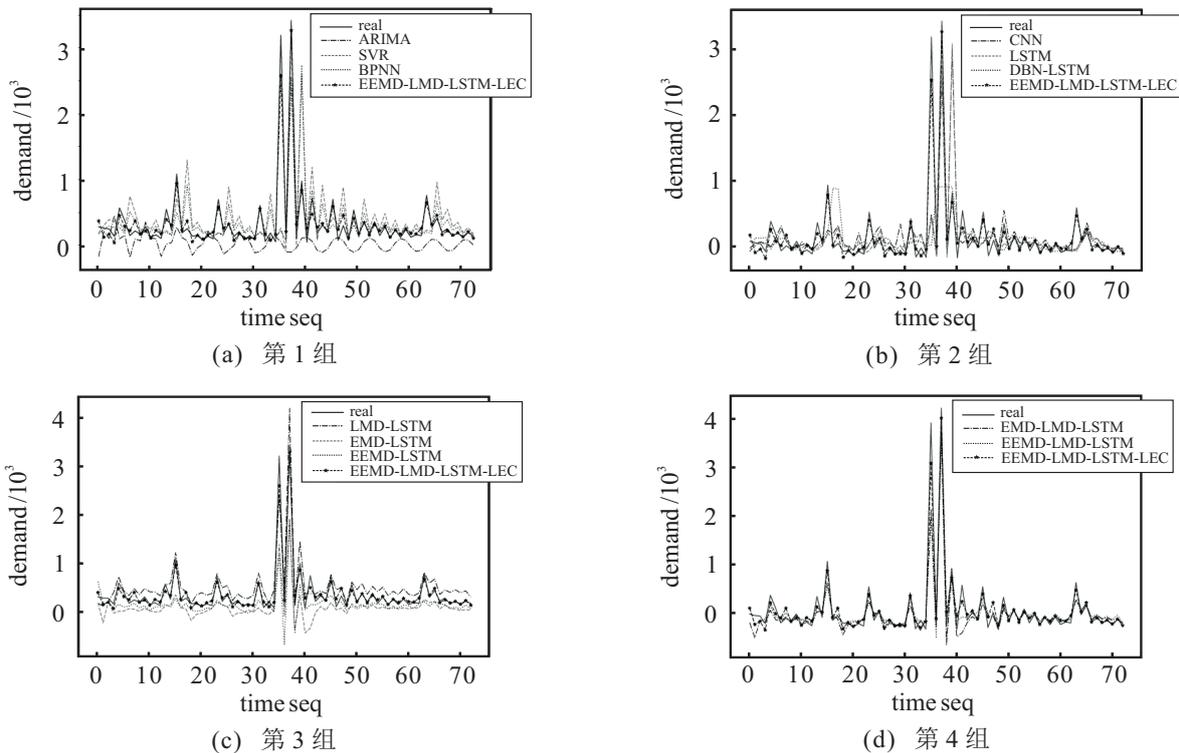


图8 短时物流需求预测对比

为了更精确地评估预测精度,本文对所有模型的RMSE、MAE、MAPE和 R^2 进行对比,结果如表3所示.

由图8和表3可知,EEMD-LMD-LSTM-LEC在RMSE、MAE、MAPE和 R^2 四个指标上的性能均显著优于其他11种模型,其中 R^2 高达0.9539,说明本文所提出的模型在短时物流需求预测方面的优势.同时使用了数据分解的模型,如LMD-LSTM、EMD-LSTM、EEMD-LSTM、EMD-LMD-LSTM、EEMD-LMD-LSTM、EEMD-LMD-LSTM-LEC,预测性能显著优于其他没有使用数据分解的模型,说明了对于非平稳性强、随机性强的短时物流需求而言,数据分解的重要性.此外,可以看出,EEMD-LSTM与LMD-LSTM的预测性能优于EMD-LSTM,说明EEMD与

LMD能有效解决EMD的模式混叠问题及端点效应问题;EEMD-LMD-LSTM的预测性能优于EEMD-LSTM与LMD-LSTM,说明EEMD与LMD的组合能有效结合两个单一分解模型的优势;EEMD-LMD-LSTM-LEC的预测性能优于EEMD-LMD-LSTM,从而验证了LEC的局部校正的有效性.

3.5 预测模型的泛化能力

模型的泛化能力体现了其对不同数据的适应能力,在使用3.1节数据验证模型有效性之外,为了进一步验证所建立的预测模型的有效性,体现其泛化能力,本文专门收集了某企业的空调产品类的物流需求数据361条,同样选择12h的时间间隔对数据集进行统计,数据分布如图9所示.对该数据的突变阈值 a 进行了参数寻优,结果如表4所示.

表3 各预测模型的预测误差对比

模型	评价指标			
	RMSE	MAE	MAPE/%	R ²
ARIMA	635.582 8	330.868 5	103.119 6	-0.384 2
SVR	489.351 7	268.661 1	94.825 3	0.179 5
BPNN	462.683 5	213.727 0	65.494 1	0.266 5
CNN	438.579 0	211.712 0	80.637 6	0.340 9
LSTM	437.140 0	186.013 0	57.794 0	0.345 0
DBN-LSTM	527.029 6	251.657 0	113.263 7	0.048 3
LMD-LSTM	245.069 1	203.133 2	127.149 5	0.794 2
EMD-LSTM	409.154 9	278.364 1	114.139 6	0.426 4
EEMD-LSTM	395.394 6	229.454 6	82.428 3	0.464 3
EMD-LMD-LSTM	215.540 9	115.186 6	48.633 8	0.840 8
EEMD-LMD-LSTM	214.708 7	113.275 9	53.962 4	0.842 0
EEMD-LMD-LSTM-LEC	115.950 7	78.872 3	43.642 2	0.953 9

表5 各预测模型的预测误差对比——空调数据

模型	评价指标			
	RMSE	MAE	MAPE/%	R ²
ARIMA	103.621 8	54.968 7	261.731 4	-0.144 2
SVR	94.540 7	67.467 7	542.987 9	0.047 5
BPNN	93.420 0	52.655 2	374.972 7	0.070 0
CNN	104.788 1	60.822 2	430.588 4	-0.170 1
LSTM	91.496 0	51.072 9	370.161 4	0.107 9
DBN-LSTM	102.389 4	62.000 2	504.850 0	-0.117 2
LMD-LSTM	54.024 2	36.246 1	414.231 8	0.6890 0
EMD-LSTM	86.027 1	48.085 2	203.102 7	0.211 3
EEMD-LSTM	75.251 9	48.391 7	232.047 8	0.396 5
EMD-LMD-LSTM	55.620 4	32.777 6	209.516 8	0.670 3
EEMD-LMD-LSTM	50.729 1	31.408 1	189.398 6	0.725 8
EEMD-LMD-LSTM-LEC	36.994 8	25.127 9	214.474 2	0.854 2

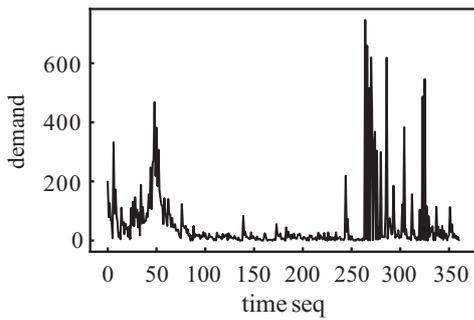


图9 空调类短时物流需求分布

表4 a取不同值的评价指标——空调数据

a 值	评价指标			
	RMSE	MAE	MAPE/%	R ²
0	39.164 7	26.150 0	197.425 3	0.836 5
10	38.975 5	25.748 8	198.245 1	0.838 1
20	36.994 8	25.127 9	214.474 2	0.854 2
30	37.751 9	25.967 2	212.257 0	0.848 1
40	37.679 4	25.822 8	210.931 4	0.848 7
50	37.721 2	25.799 6	208.124 4	0.848 4
100	38.217 5	25.678 1	204.779 0	0.844 4

由表4可知, a取20时预测性能最佳. 模型其他参数设置同前文.

不同模型的预测效果如表5所示. 由表5可知, 对于空调产品类的短时物流需求数据, 本文所构建的EEMD-LMD-LSTM-LEC模型的预测效果均显著优于上述11种对比模型, 进一步验证了所建模型在短时物流需求预测方面的有效性.

4 结论

本文针对短时物流需求预测设计了EEMD-LMD-LSTM-LEC预测模型. 考虑到数据的非平稳性、强随机性、非线性等特征, 设计了第1阶段的EEMD-LMD-LSTM模型, 对原始特征进行有效分解与提取. 同时, 考虑到短时物流需求数据的局部突变特征, 设计了第2阶段的LEC模型, 通过挖掘预测误差序列的内部特征, 对第1阶段的预测值进行校正, 提升了预测精度.

为保证获得较佳的预测效果, 对所建模型中LSTM模型的隐藏层单元数q和LEC模型的突变阈值a进行参数寻优. 实验表明, 隐藏层单元数大小为4时, 模型预测的精确性更高; a值为50时, LEC模型能有效提升预测性能.

为了验证EEMD-LMD-LSTM-LEC模型用于短时物流需求预测的效果, 本文同时设置了ARIMA、SVR、BPNN、CNN、LSTM、DBN-LSTM、LMD-LSTM、EMD-LSTM、EEMD-LSTM、EMD-LMD-LSTM以及EEMD-LMD-LSTM模型作为对比模型. 实验结果表明, 本文所提出的模型在RMSE、MAE、MAPE和R²四个指标方面均优于其他11种模型, 从而验证了EEMD-LMD-LSTM-LEC模型对于短时物流需求预测的有效性.

为了进一步验证模型的泛化性能, 本文选取空调产品类的短时物流需求数据进行模型的泛化性实验, 实验结果再次验证了本文所提出的EEMD-LMD-LSTM-LEC模型在短时物流需求预测上的有效性和优越性.

对于未来研究,可考虑针对更小统计时间间隔(如4h,6h等)的短时物流需求数据进行预测,并进一步提升预测模型的泛化能力。

参考文献(References)

- [1] 李国祥, 马文斌, 夏国恩. 基于深度学习的物流需求预测模型研究[J]. 系统科学学报, 2021, 29(2): 85-89.
(Li G X, Ma W B, Xia G E. Research on logistics demand forecast mode based on deep learning[J]. Chinese Journal of Systems Science, 2021, 29(2): 85-89.)
- [2] Duan J D, Wang P, Ma W T, et al. Short-term wind power forecasting using the hybrid model of improved variational mode decomposition and correntropy long short-term memory neural network[J]. Energy, 2021, 214: 118980.
- [3] Balocchi R, Menicucci D, Varanini M. Empirical mode decomposition to approach the problem of detecting sources from a reduced number of mixtures[C]. Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Cancun, 2003: 2443-2446.
- [4] Wu Z H, Huang N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.
- [5] Smith J S. The local mean decomposition and its application to EEG perception data[J]. Journal of the Royal Society, Interface, 2005, 2(5): 443-454.
- [6] Tian Z D. Short-term wind speed prediction based on LMD and improved FA optimized combined kernel function LSSVM[J]. Engineering Applications of Artificial Intelligence, 2020, 91: 103573.
- [7] Chen H, He H. Reverse logistics demand forecasting under demand uncertainty[C]. International Conference of Logistics Engineering and Management (ICLEM) 2010. Chengdu, 2010: 343-348.
- [8] 孔德璇, 张亚平. 寒地城市地铁站短时步行交通需求动态预测模型[J]. 交通信息与安全, 2019, 37(4): 102-111.
(Kong D X, Zhang Y P. A dynamic forecasting model of short-time traffic demand for metro station pedestrians in cold region cities[J]. Journal of Transport Information and Safety, 2019, 37(4): 102-111.)
- [9] 田中大, 李树江, 王艳红, 等. 基于ARIMA补偿ELM的网络流量预测方法[J]. 信息与控制, 2014, 43(6): 705-710.
(Tian Z D, Li S J, Wang Y H, et al. Network traffic prediction method based on extreme learning machine with ARIMA compensation[J]. Information and Control, 2014, 43(6): 705-710.)
- [10] 谈成薇, 朱贺, 赵晓敏. 基于多元线性回归模型的上海市物流需求分析[J]. 物流技术, 2016, 35(1): 34-37.
(Tan C W, Zhu H, Zhao X M. Analysis of logistics demand of Shanghai based on multiple linear regression model[J]. Logistics Technology, 2016, 35(1): 34-37.)
- [11] 江雪. 基于多元线性回归的山东省区域物流需求分析[J]. 物流技术, 2015, 34(24): 121-123.
(Jiang X. Analysis of regional logistics demand of Shandong based on multiple linear regression[J]. Logistics Technology, 2015, 34(24): 121-123.)
- [12] Yang D N. Logistics demand forecast model for port import and export in coastal area[J]. Journal of Coastal Research, 2020, 103(sp1): 678.
- [13] 刘艳利, 伍大清. 基于改进BP神经网络的水产品冷链物流需求预测研究——以浙江省为例[J]. 中国渔业经济, 2020, 38(5): 93-101.
(Liu Y L, Wu D Q. Research on cold chain logistics demand prediction of aquatic products based on improved BP Neural Network: A case study of Zhejiang Province[J]. Chinese Fisheries Economics, 2020, 38(5): 93-101.)
- [14] Hu Z N, Zhang Y X, Yao L M. Radial basis function neural network with particle swarm optimization algorithms for regional logistics demand prediction[J]. Discrete Dynamics in Nature and Society, 2014, 2014: 414058.
- [15] 曹志强, 杨箏, 刘放. 基于遗传算法优化支持向量回归机的区域物流需求预测[J]. 系统科学学报, 2018, 26(4): 79-82.
(Cao Z Q, Yang Z, Liu F. Logistics volume forecast model of support vector regression optimized by genetic algorithm[J]. Chinese Journal of Systems Science, 2018, 26(4): 79-82.)
- [16] Yu N, Xu W, Yu K L. Research on regional logistics demand forecast based on improved support vector machine: A case study of Qingdao city under the new free trade zone strategy[J]. IEEE Access, 2020, 8: 9551-9564.
- [17] Plakandaras V, Papadimitriou T, Gogas P. Forecasting transportation demand for the US market[J]. Transportation Research Part A: Policy and Practice, 2019, 126: 195-214.
- [18] 吕靖, 陈宇姝. 大连水产品冷链物流需求影响因素分析及其预测[J]. 数学的实践与认识, 2020, 50(15): 72-80.
(Lv J, Chen Y S. Dalian aquatic products cold chain logistics demand forecast and analysis of influencing factors[J]. Mathematics in Practice and Theory, 2020, 50(15): 72-80.)
- [19] Lin G C, Lin A J, Cao J N. Multidimensional KNN algorithm based on EEMD and complexity measures in financial time series forecasting[J]. Expert Systems with Applications, 2021, 168: 114443.
- [20] Li S Q, Liu X M, Lin A J. Fractional frequency hybrid model based on EEMD for financial time series forecasting[J]. Communications in Nonlinear Science and Numerical Simulation, 2020, 89: 105281.
- [21] Zhao L, Gong J X, Chong H. The extraction method of gearbox compound fault features based on EEMD and cloud model[J]. Mathematical Problems in Engineering, 2020, 2020: 6661975.

- [22] Jia L S, Zhang Q, Zheng X, et al. The empirical optimal envelope and its application to local mean decomposition[J]. *Digital Signal Processing*, 2019, 87: 166-177.
- [23] Yu J B, Lv J X. Weak fault feature extraction of rolling bearings using local mean decomposition-based multilayer hybrid denoising[J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66(12): 3148-3159.
- [24] Jiang Y, Liu S Y, Peng L L, et al. A novel wind speed prediction method based on robust local mean decomposition, group method of data handling and conditional kernel density estimation[J]. *Energy Conversion and Management*, 2019, 200: 112099.
- [25] 邱小梦, 王奉伟, 周世健, 等. 局部均值分解和奇异值分解在GNSS站坐标时间序列信号降噪中的应用[J]. *测绘通报*, 2020(5): 85-89.
(Qiu X M, Wang F W, Zhou S J, et al. Application of local mean decomposition and singular value decomposition in noise reduction of GNSS station coordinate time series signal[J]. *Bulletin of Surveying and Mapping*, 2020(5): 85-89.)
- [26] Tian Z D. Short-term wind speed prediction based on LMD and improved FA optimized combined kernel function LSSVM[J]. *Engineering Applications of Artificial Intelligence*, 2020, 91: 103573.
- [27] 于志军, 杨善林, 王晓佳, 等. 基于数据变换的GM(1, 1)误差校正方法[J]. *系统工程理论与实践*, 2015, 35(9): 2339-2347.
(Yu Z J, Yang S L, Wang X J, et al. Research on error correction method based on data transformational GM(1, 1)[J]. *Systems Engineering—Theory & Practice*, 2015, 35(9): 2339-2347.)
- [28] 杨红英, 冯双磊, 王勃, 等. 基于线性回归的风电功率预测误差修正方法[J]. *电力系统及其自动化学报*, 2013, 25(4): 14-17.
(Yang H Y, Feng S L, Wang B, et al. Study of the MOS method based on linear regression for wind power prediction[J]. *Proceedings of the CSU-EPSA*, 2013, 25(4): 14-17.)
- [29] 孙冬梅, 陈玲, 朱靳. 基于ARIMA模型误差修正的小波神经网络风速短期预测[J]. *计算机与应用化学*, 2013, 30(3): 322-326.
(Sun D M, Chen L, Zhu J. Short-term forecasting of wind speed based on wavelet neural network and ARIMA model of error correct[J]. *Computers and Applied Chemistry*, 2013, 30(3): 322-326.)
- [30] 肖逸, 李程煌, 刘若平, 等. 基于风速局部爬坡误差校正的风电功率优化预测[J]. *电力自动化设备*, 2019, 39(3): 182-188.
(Xiao Y, Li C H, Liu R P, et al. Optimal wind power prediction based on local ramp error correction of wind speed[J]. *Electric Power Automation Equipment*, 2019, 39(3): 182-188.)
- [31] Hou Z L, Zuo B, Zhang S Q, et al. Model forecast error correction based on the local dynamical analog method: An example application to the ENSO forecast by an intermediate coupled model[J]. *Geophysical Research Letters*, 2020, 47(19): e2020GL088986.
- [32] Liu H Y, Jia J H, Lin Z S, et al. Relationship between net primary production and climate change in different vegetation zones based on EEMD detrending—A case study of northwest China[J]. *Ecological Indicators*, 2021, 122: 107276.
- [33] Guo A P, Jiang A J, Lin J, et al. Data mining algorithms for bridge health monitoring: Kohonen clustering and LSTM prediction approaches[J]. *The Journal of Supercomputing*, 2020, 76(2): 932-947.
- [34] Yan H R, Qin Y, Xiang S, et al. Long-term gear life prediction based on ordered neurons LSTM neural networks[J]. *Measurement*, 2020, 165: 108205.
- [35] Zheng H T, Yuan J B, Chen L. Short-term load forecasting using EMD-LSTM neural networks with a xgboost algorithm for feature importance evaluation[J]. *Energies*, 2017, 10(8): 1168.
- [36] 黄文聪, 张宇, 张隽怡, 等. 基于时间序列突变误差校正的超短期风速联合预测模型[J]. *昆明理工大学学报: 自然科学版*, 2020, 45(4): 73-84.
(Huang W C, Zhang Y, Zhang J Y, et al. An ultra-short-term wind speed joint prediction model based on time series catastrophe error correction[J]. *Journal of Kunming University of Science and Technology: Natural Science*, 2020, 45(4): 73-84.)

作者简介

冉茂亮(1997—), 女, 硕士生, 从事物流配送资源优化、深度学习的研究, E-mail: ranmaoliang@my.swjtu.edu.cn;

陈彦如(1974—), 女, 教授, 博士生导师, 从事物流配送资源优化、机器学习等研究, E-mail: chenyanru@swjtu.edu.cn;

杨新彪(1998—), 男, 硕士生, 从事物流配送资源优化、深度学习的研究, E-mail: YoungXB@my.swjtu.edu.cn.

(责任编辑: 李君玲)