



中国科技期刊卓越行动计划项目入选期刊

# 控制与决策

CONTROL AND DECISION



## 基于VMD-EWT-QWLSTM-TPE深度学习模型的超短时物流需求多步预测

杨新彪, 陈彦如, 秦娟, 冉茂亮

引用本文:

杨新彪, 陈彦如, 秦娟, 冉茂亮. 基于VMD-EWT-QWLSTM-TPE深度学习模型的超短时物流需求多步预测[J]. 控制与决策, 2024, 39(6): 1859-1868.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.1626>

### 您可能感兴趣的其他文章

#### Articles you may be interested in

#### 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>

#### 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>

#### 基于小波变换与差分变异BSO-BP算法的大坝变形预测

Dam deformation prediction based on wavelet transform and differential mutation BSO-BP algorithm

控制与决策. 2021, 36(7): 1611-1618 <https://doi.org/10.13195/j.kzyjc.2019.1431>

#### 基于改进堆叠自动编码器的循环冷却水系统工艺介质温度预测控制方法

Predictive control method of process medium temperature in circulating cooling water system based on improved stacked auto encoders

控制与决策. 2020, 35(12): 2835-2844 <https://doi.org/10.13195/j.kzyjc.2019.0694>

# 基于VMD-EWT-QWLSTM-TPE深度学习模型的 超短时物流需求多步预测

杨新彪<sup>1</sup>, 陈彦如<sup>1,2†</sup>, 秦娟<sup>1</sup>, 冉茂亮<sup>1</sup>

(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:** 超短时物流需求预测是企业物流资源智能调度的重要基础, 然而, 超短时物流需求数据具有强随机性、高波动性、非平稳性等特征, 进行多步精确预测较为困难. 基于此, 构建基于串行数据分解和量子加权深度网络的超短时物流需求多步预测模型. 首先, 通过变分模态分解(VMD)和经验小波变换(EWT)的串行分解方法对超短时物流需求数据的时序特征进行有效提取, 以剥离噪声信号, 降低原始数据的非平稳性和随机性; 然后, 构建量子加权长短期记忆神经网络(QWLSTM)深度学习模型, 设计多输入多输出策略对分解后的模态分量进行多步预测, 并基于树形 Parzen 评估器(TPE)对 QWLSTM 的超参数组进行优化; 最后, 对各模态分量的预测结果进行重构. 实验结果表明, 所提出模型在平均绝对值误差(MAE)、均方误差(MSE)、加权平均绝对百分比误差(WMAPE)、校正决定系数( $R^2$ )方面, 均优于其他 15 种对比模型.

**关键词:** 超短时物流需求; 多步预测; 串行数据分解; 量子加权; 深度学习模型; TPE 参数优化

中图分类号: TP181

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.1626

**引用格式:** 杨新彪, 陈彦如, 秦娟, 等. 基于 VMD-EWT-QWLSTM-TPE 深度学习模型的超短时物流需求多步预测[J]. 控制与决策, 2024, 39(6): 1859-1868.

## Multi-step prediction of ultra-short-term logistics demand based on VMD-EWT-QWLSTM-TPE deep learning model

YANG Xin-biao<sup>1</sup>, CHEN Yan-ru<sup>1,2†</sup>, QIN Juan<sup>1</sup>, RAN Mao-liang<sup>1</sup>

(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:** Ultra-short-term logistics demand forecasting is important for intelligent scheduling of enterprise logistics resources. As ultra-short-term logistics demand data is random, highly volatile, and nonstationary, it is difficult to accurately predict them for multi-steps. Considering such characteristics, this research proposes a combination model for ultra-short-term logistics demand forecasting based on the serial data decomposition and quantum-weighted deep neural network. Firstly, the time series features of the ultra-short-term logistics demand data are extracted with the decomposition method of serializing variational mode decomposition (VMD) and empirical wavelet transform (EWT) to strip the noise signal and reduce the non-stationarity and randomness of the original data. Secondly, a quantum-weighted long short-term memory neural network (QWLSTM) deep learning model is developed and a multi-input multi-output strategy is designed to predict the decomposed mode components in multi-steps, also the hyper-parameters of the QWLSTM are optimized by the Tree-Parzen-Estimator (TPE). Finally, the prediction results for each mode component are reconstructed. Numerous experiments are conducted, and the results show that the proposed model performs better than other 15 comparison models.

**Keywords:** ultra-short-term logistics demand; multi-step forecast; serial data decomposition; quantum weighted; deep learning model; TPE parameters optimization

收稿日期: 2022-09-13; 录用日期: 2023-03-12.

基金项目: 国家自然科学基金项目(71771190).

责任编辑: 唐加福.

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

\*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

## 0 引言

随着大数据、物联网等新一代信息技术的迅猛发展,以24小时或12小时为间隔的短时物流需求和以1小时或更短时间的超短时物流需求,已成为物流业高效配置资源的重要决策依据.虽然以年为单位的长时物流需求预测研究,对于长期性战略制定具有指导意义,但是,对超短时物流需求进行多步预测,更能够获得微小时间粒度下包含单步在内的多个步长的长序列预测结果.它能够精准反应物流需求在子日间隔(sub-daily)、小时间隔下的微观变化趋势.企业可根据未来多个时段的物流需求情况,进行物流资源部署和调度,提高资源的利用率,实现物流系统供需多维度高效率的精准匹配.

相对于长时物流需求和短时物流需求,超短时物流需求数据的波动性、随机性、非平稳性特征更为突出,预测复杂度更高.此外,多步预测需要对同为长序列的输入数据与输出数据间的非线性关联规律进行精准建模,相较于单步预测挑战更大.因此,本文提出基于变分模态分解、经验小波变换、量子加权长短期记忆神经网络和树形Parzen评估器的深度学习混合模型(VMD-EWT-QWLSTM-TPE),用于超短时物流需求多步预测.所提出模型首先采用串行数据分解的方式对超短时物流需求数据的时序特征进行有效提取:1)通过变分模态分解(VMD)对原始超短时物流需求数据进行分解来剥离其中的噪声信号;2)通过经验小波变换(EWT)对VMD分解后的残差分量进行2次分解,以获得更具线性特征的分量,从而降低原始超短时物流需求数据的复杂特征.为了避免误差累积、延续时间序列的连贯性并降低训练成本,本文基于多输入多输出(MIMO)策略,对超短时物流需求的长时间输入序列进行深度学习建模,进而实现多步预测.长短期记忆神经网络(LSTM)在时序预测建模问题具有长时记忆优势<sup>[1]</sup>,适用于较多数长时间序列的预测问题,但是输入输出序列过长时,LSTM存在误差累积<sup>[2]</sup>且结构复杂、训练参数多,易出现过拟合风险<sup>[3]</sup>等问题.因此,本文引入量子过程,构建量子加权长短期记忆神经网络(QWLSTM)多步预测模型,通过其优越的非线性逼近能力和泛化性能<sup>[4]</sup>,提升多步预测精度,此外,引入基于树形Parzen评估器(TPE)对QWLSTM的参数进行优化来改进训练效果.

## 1 文献综述

### 1.1 物流需求预测

现有的物流需求预测模型主要分为数理统计模型、浅层机器学习模型、深度学习模型以及组合模型.

在数理统计模型方面主要有多元线性回归预测<sup>[5]</sup>、灰色模型<sup>[6]</sup>等;浅层机器学习模型包括支持向量机(SVM)<sup>[7]</sup>、BPNN<sup>[8]</sup>等;在深度学习模型方面主要有长短时记忆网络(LSTM)<sup>[1,9]</sup>;组合模型主要有基于差分整合移动平均自回归(ARIMA)和主成分回归的组合模型<sup>[10]</sup>,基于蝙蝠算法和BP神经网络的组合预测模型<sup>[11]</sup>,基于SVM、遗传算法、粒子群算法和BP神经网络的两阶段组合预测模型<sup>[12]</sup>.

数理统计模型以统计学为理论基础,能够较好地解释变量间的关系,但是模型假设简单,对于短时物流需求的预测效果不理想;浅层机器学习模型能够捕捉物流需求数据的隐性规律,但是特征学习能力有限,泛化能力不足;深度学习模型由于具有深层结构,具有较强的特征学习能力,能够更为准确地捕捉输入输出间的复杂关联关系;混合模型相较于单一模型,能够融合多模型优势,提高预测精度.

### 1.2 量子加权神经网络

量子计算是建立在量子力学基础上的一种新型计算模式,被认为是改进神经网络的有效途径<sup>[13]</sup>.根据神经元模型的不同,可将量子神经网络分为基于通用量子门演化的量子神经网络<sup>[14]</sup>、基于参数化量子电路的量子神经网络<sup>[15]</sup>、基于量子加权的量子神经网络等.量子加权神经网络的应用也较为广泛,文献[4]提出了基于量子加权长短时记忆神经网络的方法,在旋转机械状态退化趋势预测方面具有较高的预测精度和计算效率;文献[16]构建了量子加权门控循环单元神经网络预测模型,并采用粒子群优化算法(PSO)对所提出模型的参数进行寻优,且在电力系统短期负荷预测上具有较好的预测精度和模型稳定性;文献[17]提出了基于量子加权门限重复单元神经网络(QWGRUNN)的旋转机械性态退化趋势预测方法,并在旋转机械的性态退化趋势预测上取得了较好的预测精度和计算效率.

综上所述,在物流需求预测方面已有较为丰富的研究成果,为本文提供了重要的借鉴作用,但是仍然有待扩展,如物流需求预测大多集中于长时物流需求,仅有一篇文献<sup>[10]</sup>考虑了短时需求(12小时为统计间隔)预测,而目前还鲜有文献对超短时物流需求(以1小时为统计间隔)预测进行研究.由于超短时物流需求的非平稳性、强随机性、波动性等特征,以及多步预测易导致的累积误差大、训练难度高、计算成本高等问题,已有研究方法直接应用超短时物流需求多步预测,精度难以保证.此外,已有物流需求预测均为单步预测,缺乏多步预测研究.

与已有研究相比,本文的主要内容如下:1)研究对象时间跨度小,为以1小时为统计间隔的超短时物流需求;2)输入输出均为长序列的物流需求多步预测,预测复杂度更高;3)数据呈现非常明显的波动性、随机性、非平稳性;4)数据分解与量子深度学习相结合,TPE参数优化的量子加权长短期记忆神经网络(QWLSTM)对分解分量并行预测,以提升预测精度。

## 2 VMD-EWT-QWLSTM-TPE预测模型

所提出用于超短时物流需求多步预测的VMD-EWT-QWLSTM-TPE混合模型分为:1)VMD-EWT串行分解,即基于VMD-EWT技术对数据进行串行分解;2)QWLSTM多步预测,即基于QWLSTM模型对VMD-EWT串行分解获得的多分量进行多步预测,并基于TPE算法对模型超参数进行优化;3)分量预测结果重构,形成最终的预测结果.VMD-EWT-QWLSTM-TPE混合预测模型结构如图1所示。

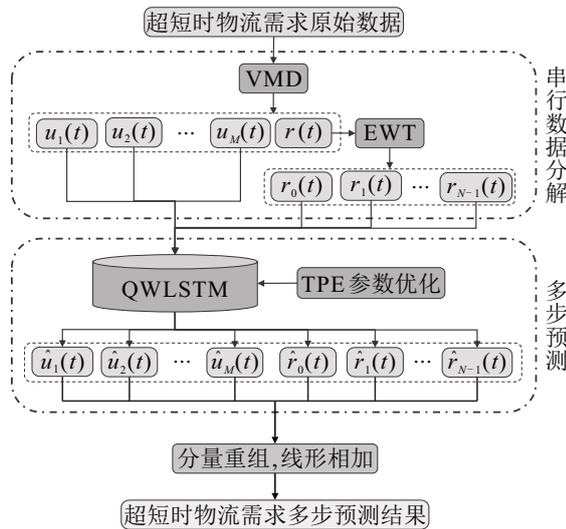


图1 VMD-EWT-QWLSTM-TPE预测模型结构

### 2.1 VMD-EWT串行分解

VMD分解后会产生一个复杂的残差分量,若忽略残差项中的丰富信息,不对其进行进一步处理,则会削弱数据的分解效果,从而影响预测<sup>[18]</sup>,因此,需要对VMD分解后的残差进一步分解,以提取蕴含的数据信息,采用串行的方式比并行的方式更能全面地提取数据信息。但是,将VMD算法置于串行分解的最后一级时,易留存一个复杂的残差分量,影响最终效果,因此,本文采用VMD-EWT的串行分解方式。

超短时物流需求数据经过VMD-EWT的串行分解模型,将数据分解为若干个具有良好周期性、更为平滑的分量数据;同时,为了减少分解数量,降低运算时间,所提出模型仅对VMD分解后的残差分量进行EWT二次分解。

### 2.1.1 超短时物流需求数据的VMD分解

VMD是由Dragomiretskiy等<sup>[19]</sup>提出的一种自适应完全非递归的信号处理方法,它将信号分解过程转化为变分问题,其分量在平稳性和平滑性方面表现更好。假设原始超短时物流需求序列 $x(t)$ 被分解为 $M$ 个模态分量,构建约束变分模型,即目标函数为最小化各模态的估计带宽和,约束条件为所有模态和与原始超短时物流需求序列相等<sup>[18]</sup>。

采用自动迭代变分算法求解上述VMD约束变分问题:首先,引入2次惩罚函数项 $\alpha$ 和拉格朗日乘子 $\lambda$ ,构造拉格朗日函数,将上述约束变分问题转变为非约束变分问题;然后,将拉格朗日函数从时域转换至频域,计算其极值并更新分量和对应的频率以及拉格朗日乘子;最后,根据是否满足迭代终止条件来决定算法的循环和终止。

当迭代过程结束,即超短时物流需求数据 $x(t)$ 经VMD分解得到了 $M$ 个模态分量 $u_1(t), u_2(t), \dots, u_M(t)$ 。一个实际信号不可能被完全分解,因此,这 $M$ 个模态分量直接相加获得的是超短时物流需求 $x(t)$ 的近似信号,其与真实的 $x(t)$ 之差为残差 $r(t)$ ,即
$$x(t) = \sum_{i=1}^M u_i(t) + r(t).$$

### 2.1.2 超短时物流需求数据残差分量的EWT二次分解

EWT算法作为一种自适应信号分解技术<sup>[20]</sup>,能够有效避免模态混叠问题,且提取的分量更少<sup>[21]</sup>。超短时物流需求数据 $x(t)$ 经VMD分解后得到 $M$ 个模态分量 $\{u_1(t), u_2(t), \dots, u_M(t)\}$ 以及残差分量 $r(t)$ 后,考虑到残差分量中仍然包含丰富的超短时物流需求的规律信息,继续对 $r(t)$ 进行EWT分解。该方法首先对 $r(t)$ 的频谱进行分割划分,然后构建合适的小波滤波器组进行分解。

超短时物流需求数据残差信号 $r(t)$ 经EWT分解为频率由低到高的调幅-调频单分量成分 $r_i(t)(i = 0, 1, \dots, N - 1)$ ,即

$$r_0(t) = w_r^\sigma(0, t)\phi_1(t); \tag{1}$$

$$r_i(t) = w_r^\sigma(n, t)\psi_i(t), \quad i = 1, 2, \dots, N - 1. \tag{2}$$

其中: $\psi_n(\omega)$ 和 $\phi_i(\omega)$ 分别为经验小波函数和经验尺度函数; $\hat{w}_r^\sigma(n, t)$ 和 $\hat{w}_r^\sigma(0, t)$ 分别为细节系数 $w_r^\sigma(n, t)$ 和近似系数 $w_r^\sigma(0, t)$ ,经傅里叶变换得到。两种函数和系数的计算过程参见文献<sup>[21]</sup>。

超短时物流需求原始数据经VMD-EWT串行分解后,得到共 $M + N$ 个模态分量,这些分量将用于下阶段的预测。

## 2.2 模态分量的QWLSTM-TPE多步预测

QWLSTM-TPE多步预测模型基于MIMO策略,针对超短时物流需求原始数据经VMD-EWT串行分解后得到的 $M+N$ 个分量,进行输入和输出数据集的构造,并设计QWLSTM神经网络对数据进行训练和预测,同时引入基于树形Parzen评估器(TPE)算法对QWLSTM的参数进行优化。

### 2.2.1 输入输出数据集的构造

超短时物流需求数据 $x(t)$ 经VMD-EWT串行分解后,得到 $M+N$ 个分量,为了便于后续计算过程的描述,将两阶段得到的模态分量整合为 $\{\mu^i(t), i=1, 2, \dots, M+N\}$ . 在基于MIMO策略的多步预测过程中,对于任意分量 $\mu^i(t)$ ,以输入长度为 $p$ 的物流需求时序模态分量数据,预测未来 $q$ 步的物流需求. 以时刻 $\tau(\tau > p)$ 为例,构造 $X_\tau^i = \{\mu_{\tau-p+1}^i, \dots, \mu_{\tau-1}^i, \mu_\tau^i\}$ 作为输入,  $Y_\tau^i = \{\mu_{\tau+1}^i, \mu_{\tau+2}^i, \dots, \mu_{\tau+q}^i\}$ 为真实值,对应期望输出为 $\hat{Y}_\tau^i = \{\hat{\mu}_{\tau+1}^i, \hat{\mu}_{\tau+2}^i, \dots, \hat{\mu}_{\tau+q}^i\}$ .

在数据集构造过程中,为了避免重复预测,时间步滑动步长设置为 $q$ ,与预测步长保持一致,因此,构造的数据集长度为 $L = (\text{len}(x(t)) - p) // q$ . 其中: $\text{len}(x(t))$ 为超短时物流需求数据长度,  $//$ 表示整除

运算. 对于模态分量 $\mu^i(t)$ 而言,所构造的输入和输出数据集如下所示:

$$X^i = \begin{bmatrix} \mu_1^i & \mu_2^i & \dots & \mu_p^i \\ \mu_{1+q}^i & \mu_{2+q}^i & \dots & \mu_{p+q}^i \\ \vdots & \vdots & \ddots & \vdots \\ \mu_{1+(L-1)q}^i & \mu_{2+(L-1)q}^i & \dots & \mu_{p+(L-1)q}^i \end{bmatrix}, \quad (3)$$

$$Y^i = \begin{bmatrix} \mu_{p+1}^i & \mu_{p+2}^i & \dots & \mu_{p+q}^i \\ \mu_{p+1+q}^i & \mu_{p+2+q}^i & \dots & \mu_{p+2q}^i \\ \vdots & \vdots & \ddots & \vdots \\ \mu_{p+1+(L-1)q}^i & \mu_{p+2+(L-1)q}^i & \dots & \mu_{p+Lq}^i \end{bmatrix}. \quad (4)$$

### 2.2.2 模态分量的QWLSTM预测模型构建

QWLSTM作为一种量子过程的神经网络,利用了量子计算强大的并行处理能力,在数据处理方面相较于传统深度网络更具有潜在优势<sup>[17]</sup>. LSTM网络是一种递归神经网络,用于解决现实世界的时间序列问题<sup>[22]</sup>,它由存储单元组成,存储单元可在每个时间步对信息进行保存和修改. 存储单元由遗忘门、输入门和输出门3个门控单元组成. QWLSTM预测模型在保持LSTM原有单元结构的同时移除了各门控单元的偏置以简化网络结构,其结构如图2所示.

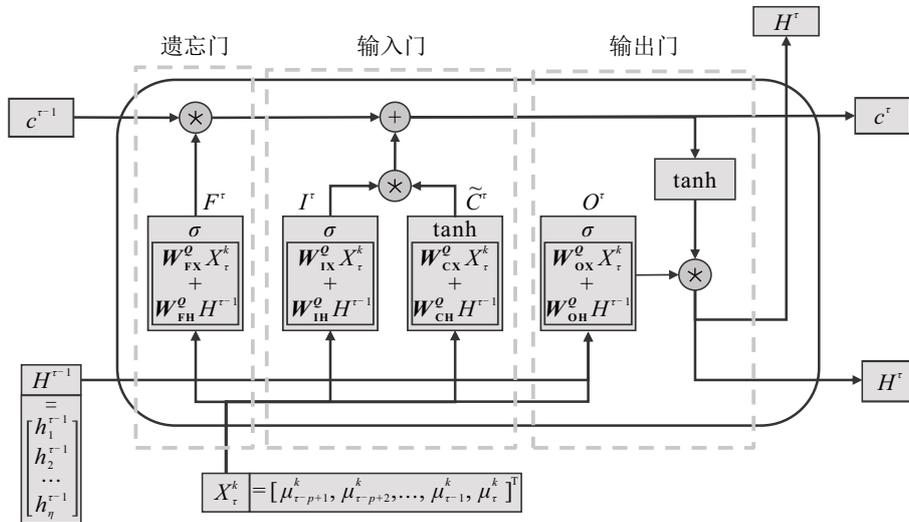


图2 模态分量的QWLSTM预测模型结构

进行超短时物流需求预测时,对于模态分量 $\mu^k(t)$ 而言,QWLSTM模型在时刻 $\tau$ 的输入数据为 $X_\tau^k = [\mu_{\tau-p+1}^k, \mu_{\tau-p+2}^k, \dots, \mu_{\tau-1}^k, \mu_\tau^k]^T$ ;上阶段单元状态为 $C^{\tau-1}$ ;上阶段隐藏状态为 $H^{\tau-1} = [h_1^{\tau-1}, h_2^{\tau-1}, \dots, h_\eta^{\tau-1}]^T$ ;  $\eta$ 为隐层大小;激活函数为sigmoid函数,用 $\sigma$ 表示. 各部分计算过程如下.

1) 输入门计算过程如下所示:

$$I^\tau = [I_1^\tau, I_2^\tau, \dots, I_\eta^\tau]^T = \sigma(\mathbf{W}_{IX}^Q X_\tau^k + \mathbf{W}_{IH}^Q H^{\tau-1}). \quad (5)$$

其中: $H^0 = [0, 0, \dots, 0]^T$ 作为初始隐层状态输入,  $\mathbf{W}_{IX}^Q$ 、 $\mathbf{W}_{IH}^Q$ 分别为输入数据 $X_\tau^k$ 的量子权值矩阵、与上阶段隐藏状态 $H^{\tau-1}$ 的量子权值矩阵. 由文献[4]可知,  $\mathbf{W}_{IX}^Q$ 的矩阵形式如下所示:

$$\mathbf{W}_{IX}^Q = [w_{ji}^{IX}]_{\eta \times p} = [\cos(\theta_{ji}^{IX} - \xi_j^{IX})]_{\eta \times p} = \begin{bmatrix} \cos(\theta_{11}^{IX} - \xi_1^{IX}) & \dots & \cos(\theta_{1p}^{IX} - \xi_1^{IX}) \\ \vdots & \ddots & \vdots \\ \cos(\theta_{\eta 1}^{IX} - \xi_\eta^{IX}) & \dots & \cos(\theta_{\eta p}^{IX} - \xi_\eta^{IX}) \end{bmatrix}. \quad (6)$$

式中:  $\theta_{ji}^X$  为量子相移门中权值量子位的相位,  $\xi_j^X$  为量子相移门中活性值量子位的相位. 同理可知, 与上阶段隐藏状态  $H^{\tau-1}$  计算的权值矩阵  $W_{IH}^Q$  的矩阵形式如下所示:

$$W_{IH}^Q = [w_{jm}^{IH}]_{\eta \times \eta} = [\cos(\theta_{jm}^{IH} - \xi_j^{IH})]_{\eta \times \eta} = \begin{bmatrix} \cos(\theta_{11}^{IH} - \xi_1^{IH}) & \dots & \cos(\theta_{1\eta}^{IH} - \xi_1^{IH}) \\ \vdots & \ddots & \vdots \\ \cos(\theta_{\eta 1}^{IH} - \xi_\eta^{IH}) & \dots & \cos(\theta_{\eta\eta}^{IH} - \xi_\eta^{IH}) \end{bmatrix}. \quad (7)$$

基于式(6)和(7), 整个输入门的矩阵形式计算过程如下所示:

$$I^\tau = [I_1^\tau, I_2^\tau, \dots, I_\eta^\tau]^\tau = \sigma \times \left( \begin{bmatrix} \cos(\theta_{11}^{IX} - \xi_1^{IX}) & \dots & \cos(\theta_{1p}^{IX} - \xi_1^{IX}) \\ \vdots & \ddots & \vdots \\ \cos(\theta_{\eta 1}^{IX} - \xi_\eta^{IX}) & \dots & \cos(\theta_{\eta p}^{IX} - \xi_\eta^{IX}) \end{bmatrix} \begin{bmatrix} \mu_{\tau-p+1}^k \\ \vdots \\ \mu_\tau^k \end{bmatrix} + \begin{bmatrix} \cos(\theta_{11}^{IX} - \xi_1^{IX}) & \dots & \cos(\theta_{1p}^{IX} - \xi_1^{IX}) \\ \vdots & \ddots & \vdots \\ \cos(\theta_{\eta 1}^{IX} - \xi_\eta^{IX}) & \dots & \cos(\theta_{\eta p}^{IX} - \xi_\eta^{IX}) \end{bmatrix} \begin{bmatrix} h_1^{\tau-1} \\ \vdots \\ h_\eta^{\tau-1} \end{bmatrix} \right) = \left[ \sigma \left( \sum_{i=1}^p [\cos(\theta_{ji}^{IX} - \xi_j^{IX}) \mu_{\tau-p+i}^k] + \sum_{m=1}^{\eta} [\cos(\theta_{jm}^{IH} - \xi_j^{IH}) h_m^{\tau-1}] \right), j = 1, 2, \dots, \eta \right]^\tau. \quad (8)$$

同理, 可推导出遗忘门  $F^\tau$ 、候选单元状态  $\tilde{C}^\tau$ 、输出门的  $O^\tau$  的简要计算公式.

2) 遗忘门计算过程如下所示:

$$F^\tau = [F_1^\tau, F_2^\tau, \dots, F_\eta^\tau]^\tau = \sigma(W_{FX}^Q X_\tau^k + W_{FH}^Q H^{\tau-1}). \quad (9)$$

3) 输出门计算过程如下所示:

$$O^\tau = [O_1^\tau, O_2^\tau, \dots, O_\eta^\tau]^\tau = \sigma(W_{OX}^Q X_\tau^k + W_{OH}^Q H^{\tau-1}). \quad (10)$$

4) 候选单元状态计算过程如下所示:

$$C^\tau = [C_1^\tau, C_2^\tau, \dots, C_\eta^\tau]^\tau = \tanh(W_{CX}^Q X_\tau^k + W_{CH}^Q H^{\tau-1}). \quad (11)$$

5) 更新后单元状态计算过程如下所示:

$$C^\tau = F^\tau * C^{\tau-1} + I^\tau * \tilde{C}^\tau. \quad (12)$$

6) 单元输出计算过程如下所示:

$$H^\tau = O^\tau * \tanh(C^\tau). \quad (13)$$

其中: \* 表示对应元素相乘; 将 QWLSTM 得到的所有时刻单元的输出  $H^\tau$  经全连接层 FC 展平, 得到该分量的预测结果  $\hat{\mu}^i(t)$ .

对超短时物流需求数据  $x(t)$  分解得到的  $M + N$  个模态分量分别进行 QWLSTM 多步预测后的预测

结果进行重构, 得到对原数据的预测结果  $\hat{x}(t)$ , 即

$$\hat{x}(t) = \sum_{i=1}^{M+N} \hat{\mu}^i(t). \quad (14)$$

### 2.3 基于 TPE 的 QWLSTM 预测模型超参数优化

QWLSTM 模型中包含众多超参数, 这些超参数的取值会直接影响 QWLSTM 模型的预测性能. 为了寻找 QWLSTM 模型超参数的最优组合, 本节采用 TPE 对 QWLSTM 模型的超参数进行优化. 综合考虑优化成本和预测性能, 本文共选取了隐层大小  $\eta$ 、网络层数  $\gamma$ 、初始学习率  $\varepsilon$ 、优化器类型  $\rho$  这 4 个超参数, 基于 TPE 对其进行优化. 基于 TPE 对 QWLSTM 的预测模型超参数优化算法步骤<sup>[23]</sup>如下.

step 1: 利用随机搜索过程初始化抽样分布  $p(\theta|f(\theta))$ ,  $\theta = \{\eta, \gamma, \varepsilon, \rho\}$  为该超参数组合,  $f(\theta)$  为该超参数组合对应的评价值, 本文选取 QWLSTM 预测模型的均方误差 MSE 作为超参数的评价函数.

step 2: 根据不同超参数对应的评价值, 将低于阈值  $f^*$  的超参数组划分为  $Pr_B(\theta)$ , 高于阈值  $f^*$  的超参数组划分为  $Pr_G(\theta)$ , 阈值取值为观测数据的 MSE 的 1/4 分位数.

step 3: 计算期望改进 (EI), 即  $EI(\theta) = \frac{Pr_G(\theta)}{Pr_B(\theta)}$ , 并选择能够最大化 EI 的超参数组  $\theta^* = \{\eta^*, \gamma^*, \varepsilon^*, \rho^*\}$ .

step 4: 重复 step 2 和 step 3, 直至满足最大迭代次数  $N$ , 本文设置为 100.

通过 TPE 参数优化算法, 获取 QWLSTM 预测模型中最佳的隐层大小、网络层数、初始学习率以及优化器类型.

## 3 实验和结果分析

本研究收集了某物流公司于 2020 年 11 月 1 日 0 点~2020 年 12 月 31 日 24 点间所有时刻产生的物流需求订单数据, 共计 68 万余条. 以 1 小时作为统计间隔对数据进行处理后得到的时间序列长度为 1464, 并对统计结果进行归一化操作, 以将数据映射

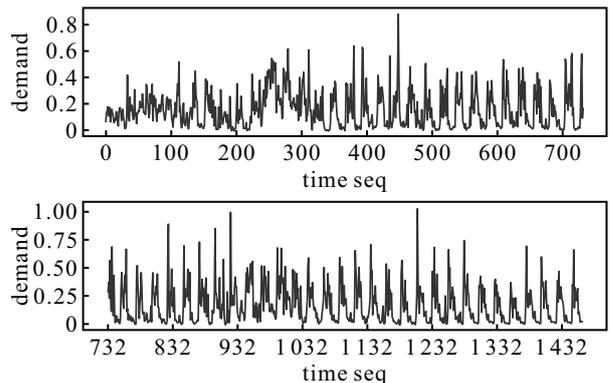


图3 1小时统计间隔下超短时物流需求时间分布

至 [0, 1] 区间上, 便于后续的分解和预测, 统计结果如图3所示.

### 3.1 模型参数设置

#### 3.1.1 VMD分解算法中带宽限制的选择

VMD分解算法中, 得到的模态分量复杂度与带宽限制  $\alpha$  呈负相关, 但是, 残差分量的复杂度与  $\alpha$  呈正相关, 且残差分量的复杂度会直接影响EWT分解分量的复杂度, 因此, 本文分别选取  $\alpha = \{5000, 4000, 3000, 2000, 1000, 100\}$  进行测试, 在预测步长为12时预测性能指标如表1所示.

表1  $\alpha$ 不同取值下的预测结果

评价指标	$\alpha = 5000$	$\alpha = 4000$	$\alpha = 3000$
MAE	0.042713	0.042021	0.041225
MSE	0.003549	0.003611	0.003392
WMAPE/%	32.6857	34.1569	34.6378
R <sup>2</sup>	0.727229	0.747169	0.770373
评价指标	$\alpha = 2000$	$\alpha = 1000$	$\alpha = 100$
MAE	0.044038	<b>0.037651</b>	0.052352
MSE	0.00392	<b>0.002897</b>	0.005586
WMAPE/%	34.8325	<b>27.6861</b>	44.3874
R <sup>2</sup>	0.697609	<b>0.819414</b>	0.538916

由表1可见, 当  $\alpha = 1000$  时, 模型的预测性能最优, 因此, 所提出VMD分解算法中  $\alpha$  设置为1000.

#### 3.1.2 QWLSTM网络参数优化

本文基于TPE对QWLSTM网络的参数进行优化, 包括网络隐层大小(hidden size)、网络层数(layer

num), 以避免出现过拟合或欠拟合现象; 然后对模型训练过程中的参数进行优化, 包括优化器类型(optimizer)和初始学习率大小(learning rate), 以提高收敛速度和收敛效果, 本文设定的参数采样空间包括: 隐层大小 = {32, 64, 96}, 网络层数 = {1, 2, 3, 4, 5}, 优化器类型 = {Adam, ASGD, RMSprop}, 初始学习率大小 = Uniform (0.001, 0.1).

模型迭代总次数为1000, 初始学习率lr随训练的迭代数每过100代, 学习率衰减为  $lr \times \mu$ , 本文将衰减因子  $\mu$  设置为0.95.

本文在训练集上进行模型训练和基于TPE算法进行参数寻优, 在测试集上进行模型的测试, 因此, 本文属于样本外预测, 且在构建数据集时, 输入序列长度  $p$  为输出长度  $q$  的4倍, 同时为了降低过拟合风险和节省训练时间, 在训练过程中引入了早停(early stopping)机制并设置patience参数为20.

### 3.2 实验结果分析

为了避免模型训练过程中出现的偶然性, 本文实验结果均为3次连续实验后的平均值.

#### 3.2.1 模型预测性能分析

##### 1) VMD-EWT串行分解.

将原始短时物流需求数据经VMD-EWT串行分解得到的分量如图4所示.

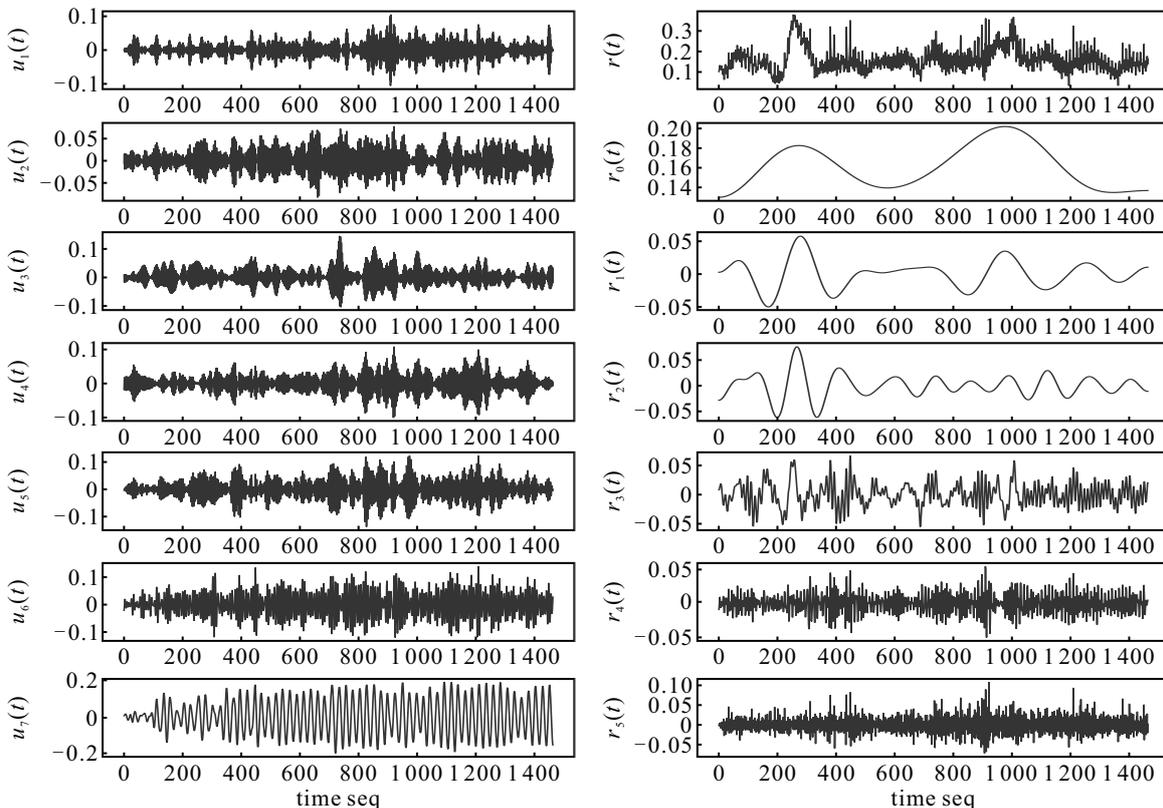


图4 VMD-EWT分解结果

图4左侧为原始超短时物流需求数据经VMD分解后得到的7个模态分量,右侧第1分量为残差分量 $r(t)$ .可以看出, $r(t)$ 在重构成原始数据时,依然占据了一定的比重,因此,对其进行EWT分解,得到如图4右侧的6个模态分量,且这些分量相较于原数据,具有更好的周期性平稳性.

2)QWLSTM-TPE预测.

本文将80%的数据划分为训练集,20%的数据划分为测试集,分别选取2、4、6、8、10、12共6种步长对所提出模型进行测试,同时对比单步预测(由于滑动步长的存在,使得不同步长下的数据集长度不同,各步长下的测试集长度不同).在不同步长下,所提出模型的预测效果表2所示.

由表2可见:当步长为12时,所提出模型有较好的预测效果,随着步长的减少,预测精度会持续提升;当步长为2时,MAE为0.01622,MSE为0.000438,WMAPE为12.718%, $R^2$ 高达0.98,而当进行单步预

表2 各步长下VMD-EWT-QWLSTM-TPE多步预测指标

预测步长	指标(平均)			
	MAE	MSE	WMAPE/%	$R^2$
12	0.037588	0.002922	26.6988	0.830761
10	0.032302	0.001912	23.7872	0.928288
8	0.022229	0.000835	16.7343	0.949909
6	0.021712	0.000806	16.2400	0.957233
4	0.019223	0.000620	13.2956	0.974076
2	0.016220	0.000438	12.7180	0.982877
1	0.018249	0.000534	13.0769	0.979161

测时,精度反而有一定的降低.

3.2.2 模型对比

为了验证所提出模型的有效性,本文选取了多种对比模型,在多个预测步长上进行验证,具体结果如表3和表4所示.本文为了对比各模型的预测效果差距,将指标结果统一映射至[0,100]上,再计算其标准差来衡量各模型的差距.

表3 模型 $M_1 \sim M_8$ 在不同步长上的预测性能对比

步长	评价指标	模型							
		$M_1$	$M_2$	$M_3$	$M_4$	$M_5$	$M_6$	$M_7$	$M_8$
12	MAE	0.162029	0.153037	0.111075	0.094294	0.099729	0.085326	0.070598	0.043023
	MSE	0.044679	0.037999	0.025646	0.017636	0.018008	0.016719	0.012244	0.003773
	WMAPE/%	114.0530	107.7236	78.8688	90.9191	94.7443	60.0610	40.7389	35.1380
	$R^2$	-2.879870	-2.590150	-1.723490	-0.623280	-0.578960	-0.045460	0.570151	0.825224
10	MAE	0.165473	0.156548	0.098495	0.102879	0.115304	0.086254	0.083244	0.043551
	MSE	0.045608	0.037897	0.019608	0.019332	0.022926	0.013837	0.014199	0.003475
	WMAPE/%	113.5586	107.4337	65.2460	72.8605	79.3068	59.1927	57.6083	30.9226
	$R^2$	-0.984770	-0.615070	0.126844	0.183221	0.024750	0.445315	0.346461	0.846137
8	MAE	0.153934	0.159644	0.075147	0.096509	0.100705	0.064299	0.072112	0.028248
	MSE	0.040305	0.040328	0.012275	0.020645	0.018441	0.008305	0.012312	0.001394
	WMAPE/%	105.7102	109.6314	54.0430	69.9891	70.0568	44.1555	52.9527	22.0006
	$R^2$	-1.232090	-1.291230	0.329382	0.016839	0.007223	0.611047	0.584429	0.938320
6	MAE	0.148672	0.150085	0.072873	0.098087	0.093614	0.062955	0.076861	0.025755
	MSE	0.040273	0.038846	0.014198	0.020093	0.017374	0.008302	0.013518	0.001204
	WMAPE/%	104.7174	105.7125	54.7908	69.0015	69.4633	44.3430	56.8494	20.1734
	$R^2$	-1.021370	-0.987790	0.484685	-0.017140	0.215116	0.632253	0.539648	0.946051
4	MAE	0.130541	0.136110	0.104121	0.129973	0.100391	0.095933	0.090089	0.022569
	MSE	0.028369	0.031714	0.023038	0.067558	0.018100	0.016856	0.017447	0.000915
	WMAPE/%	91.9472	95.8691	73.0887	92.4947	72.4678	67.5708	57.5227	17.4011
	$R^2$	-0.210160	-0.364580	-0.001100	-0.49071	0.274658	0.320105	0.405842	0.958992
2	MAE	0.148587	0.151259	0.110096	0.108173	0.093216	0.098749	0.094560	0.021062
	MSE	0.035204	0.036145	0.027709	0.026118	0.016866	0.018727	0.020967	0.000785
	WMAPE/%	105.3136	107.2079	70.2953	69.5562	65.9215	69.9904	66.1128	17.1512
	$R^2$	-0.430150	-0.470590	-0.039570	-0.007550	0.367586	0.256376	0.285152	0.964695
1	MAE	0.093335	0.101104	0.130695	0.080967	0.082432	0.092196	0.057526	0.029081
	MSE	0.017068	0.016963	0.025384	0.014201	0.014301	0.016845	0.006787	0.001337
	WMAPE/%	66.5562	72.0959	93.1967	57.7369	58.7819	65.7444	41.0214	20.7371
	$R^2$	0.308709	0.312972	-0.028120	0.424813	0.420770	0.317727	0.725094	0.945849

表4 模型  $M_9 \sim M_{16}$  在不同步长上的预测性能对比

步长	评价指标	模型							
		$M_9$	$M_{10}$	$M_{11}$	$M_{12}$	$M_{13}$	$M_{14}$	$M_{15}$	$M_{16}$
12	MAE	0.041 843	0.043 373	0.037 469	0.047 599	0.038 330	0.054 014	0.037 822	<b>0.037 588</b>
	MSE	0.003 731	0.003 829	0.002 965	0.005 801	0.003 061	0.006 109	0.003 084	<b>0.002 922</b>
	WMAPE/%	31.260 8	30.530 8	<b>26.334 3</b>	36.790 1	32.326 0	38.021 2	27.556 6	26.698 8
	$R^2$	0.827 157	0.766 680	0.827 511	0.765 776	0.797 454	0.747 934	0.814 658	<b>0.830 761</b>
10	MAE	0.042 587	0.040 067	0.032 815	0.053 547	0.037 524	0.047 175	0.035 13	<b>0.032 302</b>
	MSE	0.003 387	0.002 871	0.001 924	0.005 827	0.002 578	0.004 196	0.002 376	<b>0.001 912</b>
	WMAPE/%	28.863 7	27.496 5	24.712 1	37.154 0	25.259 4	32.374 6	25.478 0	<b>23.787 27</b>
	$R^2$	0.850 068	0.882 48	0.923 82	0.773 846	0.898 447	0.832 261	0.904 371	<b>0.928 288</b>
8	MAE	0.033 577	0.028 454	0.023 561	0.043 991	0.025 682	0.034 913	0.025 473	<b>0.022 229</b>
	MSE	0.001 874	0.001 31	0.000 925	0.004 348	0.001 069	0.002 211	0.001 086	<b>0.000 835</b>
	WMAPE/%	24.504 4	19.540 0	19.955 3	31.235 2	22.410 8	23.975 8	16.875 4	<b>16.734 3</b>
	$R^2$	0.917 098	0.919 103	0.944 439	0.831 803	0.937 503	0.911 697	0.932 908	<b>0.949 909</b>
6	MAE	0.026 522	0.028 218	0.022 861	0.045 521	0.022 122	0.035 524	0.023 226	<b>0.021 712</b>
	MSE	0.001 248	0.001 409	0.000 888	0.004 537	0.000 875	0.002 049	0.000 899	<b>0.000 806</b>
	WMAPE/%	20.386 3	19.875 3	17.840 0	32.567 2	17.541 2	25.021 3	16.512 7	<b>16.240 0</b>
	$R^2$	0.944 055	0.927 999	0.952 569	0.822 575	0.954 188	0.917 409	0.952 213	<b>0.957 233</b>
4	MAE	0.021 945	0.023 814	0.020 095	0.048 922	0.019 668	0.027 476	0.019 849	<b>0.019 223</b>
	MSE	0.000 832	0.000 926	0.000 695	0.005 132	0.000 677	0.001 43	0.000 691	<b>0.000 62</b>
	WMAPE/%	17.470 9	16.773 5	16.626 4	35.337 7	<b>13.117 6</b>	19.352 7	14.283 0	13.295 6
	$R^2$	0.962 706	0.959 392	0.970 766	0.799 309	0.971 377	0.942 352	0.971 2	<b>0.974 076</b>
2	MAE	0.023 339	0.023 663	0.018 734	0.054 259	0.017 537	0.027 446	0.017 414	<b>0.016 22</b>
	MSE	0.000 895	0.000 962	0.000 581	0.006 411	0.000 521	0.001 468	0.000 537	<b>0.000 438</b>
	WMAPE/%	19.016 5	16.771 7	13.771 6	40.481 0	<b>12.331 2</b>	19.453 7	13.218 7	12.718 1
	$R^2$	0.959 761	0.960 212	0.977 451	0.748 751	0.979 668	0.940 657	0.979 483	<b>0.982 877</b>
1	MAE	0.029 201	0.023 091	<b>0.018 007</b>	0.041 775	0.046 746	0.039 398	0.018 673	0.018 25
	MSE	0.001 284	0.000 897	0.000 546	0.003 224	0.003 089	0.002 596	0.000 584	<b>0.000 534</b>
	WMAPE/%	20.823 1	16.466 3	<b>12.903 6</b>	29.790 2	33.495 9	28.094 7	13.380 6	13.076 9
	$R^2$	0.947 963	0.963 637	0.978 702	0.869 402	0.879 636	0.894 844	0.977 215	<b>0.979 161</b>

本文选择了多种对比模型,包括:基于直接策略的多元线性回归(MLR),为了简化后续描述,用  $M_1$  表示;基于直接策略的 SVR( $M_2$ ) 以及 BPNN( $M_3$ ); LSTM( $M_4$ )、QWLSTM( $M_5$ );基于蝙蝠算法和 BPNN 的 BA-BPNN 模型( $M_6$ )。以上模型均未引入分解模型。本文针对引入数据分解的组合模型做出了多维度对比,包括 VMD-LSTM( $M_7$ )、VMD-EEMD-LSTM( $M_8$ )、VMD-LMD-LSTM( $M_9$ )、VMD-LMD-QWLSTM( $M_{10}$ )、VMD-EWT-GRU( $M_{11}$ )、VMD+EWT-LSTM\*( $M_{12}$  为并行分解)、EWT-VMD-LSTM( $M_{13}$ )、VMD-EWT-LSTM( $M_{14}$ )、VMD-EWT-QWLSTM( $M_{15}$ )、VMD-EWT-QWLSTM-TPE( $M_{16}$  为所提出模型)。

由表3和表4可见,所提出预测模型在不同步长的预测中均显著优于其他15种模型,尤其在2步预测

时  $R^2$  达到了 0.982 877,表明了所提出模型在超短时物流需求预测方面的优势。

通过对比模型  $M_1 \sim M_3$  的预测结果可知,数理统计模型和浅层机器学习模型在具有复杂时序特征的超短时物流需求预测上难以取得较好效果;由  $M_4$  和  $M_5$  的预测结果可知,尽管特征学习能力相较于前两类模型有一定的提升,但是,直接应用于超短时物流需求时预测效果仍然很差;通过对比  $M_3$  与  $M_6$  可以发现,基于浅层机器学习模型的组合模型能够在一定程度上提高预测的效果,但是仍然不能有很好的预测精度;从  $M_7 \sim M_{16}$  的结果来看,这些模型增加了数据分解过程,提取了超短时物流需求数据的复杂时序特征,有效地提升了预测精度。

进一步地,  $M_7$  与其他模型相比,由于仅使用了

单一数据分解方法,其效果劣于使用两种数据分解方法的预测模型。此外,所提出VMD和EWT两种分解算法,其预测性能均优于其他分解算法,如EEMD和LMD,同时,VMD-EWT串行方式不仅优于EWT-VMD的串行方式,也优于两者并行的分解方式。

通过对比 $M_{14}$ 与 $M_{15}$ 可以发现,在较长的预测步长(10步、12步)上,QWLSTM相较于LSTM表现更好,且随着预测步长的增加,QWLSTM预测精度的衰减相较于LSTM更慢,这意味着QWLSTM在更长的步长上能够比LSTM保持更高的预测优势;通过对比 $M_{15}$ 与 $M_{16}$ 可以发现,参数优化后的模型对数据的时序特征的学习能力更强,与数据的契合度更高,其预测精度得到了进一步提升。

通过对比多步与单步预测可以发现,数理统计模型、浅层机器学习模型以及单一深度学习模型在单步预测时,效果有一定的提升,但是总体来看,效果依然不理想。然而,在深度组合模型上,多数模型在单步预测上的表现不如多步预测,如 $M_8$ 、 $M_9$ 、 $M_{13} \sim M_{16}$ ,但是总体而言,这类模型在单步预测上也能保持较高的精度。此外,所提出模型在单步预测中仍然保持优势。

结合表3和表4中各模型在各步长上的预测指标,计算得到的标准差最大为40.19%,最小为27.19%,平均为30.57%,模型间性能有较大的差异,且所提出模型有明显的优势。为了验证预测过程的实时性,本文在实验中计算了各模型的预测时间,在各步长上的预测耗时均能够满足实时性要求。所提出模型由于存在参数寻优的过程,训练时间较长,但是,测试时间快到毫秒级,因此,可将模型进行离线训练以避免训练时间过长影响预测的时效性,在实际应用中还可通过分布式训练、GPU加速等策略提高训练的效率。

## 4 结论

本文针对超短时物流需求的数据特征设计了VMD-EWT-QWLSTM-TPE预测模型,该模型通过VMD-EWT的串行数据分解算法,有效地降低了超短时物流需求数据的非平稳性和强随机性;通过设计MIMO策略下的QWLSTM预测网络,并基于TPE方法对其超参数组进行寻优,进一步提升了模型的预测性能,本文通过与15种模型对比发现:1)所设计的VMD-EWT串行分解算法,能够将具有强随机性和高波动性的超短时物流需求原始数据分解为多个具有一定周期性、相对平稳性的模态分量数据,有效降低了数据复杂度,大幅提升了多步预测精度;2)多步预

测过程中,随着预测步长的增加,模型的预测精度会不断下降,但是,量子权值的引入能够有效延缓预测精度下降的趋势,在更长的预测步长方面,QWLSTM相较于LSTM更具优势;3)基于TPE进行预测模型的超参数寻优,使得模型能够更好地学习数据的时序特征,进一步提高了模型的预测精度。

在未来的研究中,可以考虑将更新颖的量子加权神经网络设计为主要的网络层,以在更长预测步长(如24、48等)的情况下,进一步提高预测精度。

## 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] Pimpalkar A, Raj J R R. MBiLSTM GloVe: Embedding GloVe knowledge into the corpus using multi-layer BiLSTM deep learning model for social media sentiment analysis[J]. Expert Systems with Applications, 2022, 203: 117581.
- [3] Liu H Y, Han H, Sun Y, et al. Short-term wind power interval prediction method using VMD-RFG and Att-GRU[J]. Energy, 2022, 251: 123807.
- [4] 李锋, 陈勇, 向往, 等. 基于量子加权长短时记忆神经网络的状态退化趋势预测[J]. 仪器仪表学报, 2018, 39(7): 217-225.  
(Li F, Chen Y, Xiang W, et al. State degradation trend prediction based on quantum weighted long short-term memory neural network[J]. Chinese Journal of Scientific Instrument, 2018, 39(7): 217-225.)
- [5] 沈琪, 郭洪利. 基于多元变权组合预测模型的物流需求预测[J]. 价值工程, 2021, 40(18): 1-4.  
(Shen Q, Guo H L. Logistics demand forecasting based on multivariate combination forecasting model[J]. Value Engineering, 2021, 40(18): 1-4.)
- [6] 李义华, 王冲, 文哲, 等. 基于滑动无偏灰色模型的湖南省农产品冷链物流需求预测[J]. 中南林业科技大学学报, 2021, 41(8): 161-168.  
(Li Y H, Wang C, Wen Z, et al. Demand prediction on cold chain logistics of agricultural products in Hunan Province based on a new dimension sliding unbiased grey model[J]. Journal of Central South University of Forestry & Technology, 2021, 41(8): 161-168.)
- [7] 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.

- [8] 张姣姣. 基于改进BP神经网络的吉林省生鲜农产品冷链物流需求预测[D]. 长春: 吉林大学, 2021.  
(Zhang J J. Forecast of cold chain logistics demand for fresh agricultural products in Jilin Province based on improved BP neural network[D]. Changchun: Jilin University, 2021.)
- [9] 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.  
(Ran M L, Chen Y R, Yang X B. Short-term logistics demand forecasting based on EEMD-LMD-LSTMLEC deep learning model[J]. Control and Decision, 2022, 37(10): 2513-2523.)
- [10] 黄建华, 陈严档, 卢箫扬. 基于ARIMA-PCR模型的福建省物流需求预测[J]. 武汉理工大学学报: 信息与管理工程版, 2019, 41(6): 579-585.  
(Huang J H, Chen Y D, Lu X Y. Logistics demand forecast of Fujian Province based on ARIMA-PCR model[J]. Journal of Wuhan University of Technology: Information & Management Engineering, 2019, 41(6): 579-585.)
- [11] Han C L, Wang Q Y. Research on commercial logistics inventory forecasting system based on neural network[J]. Neural Computing and Applications, 2021, 33(2): 691-706.
- [12] 李捷, 陈彦如, 杨璐. 基于两阶段组合预测模型的区域物流需求预测[J]. 信息与控制, 2018, 47(2): 247-256.  
(Li J, Chen Y R, Yang L. Regional logistics demand forecasting based on two-stage combination prediction model[J]. Information and Control, 2018, 47(2): 247-256.)
- [13] 丁礼良. 量子神经网络模型及其算法研究[D]. 西安: 西北大学, 2009.  
(Ding L L. Research on quantum neural network model and its algorithm[D]. Xi'an: Northwest University, 2009.)
- [14] 许兴阳, 刘宏志. 基于量子门组的卷积神经网络设计与实现[J]. 计算机工程与应用, 2018, 54(20): 54-61.  
(Xu X Y, Liu H Z. Design and implementation of convolution neural network based on quantum gate group[J]. Computer Engineering and Applications, 2018, 54(20): 54-61.)
- [15] Liu J H, Lim K H, Wood K L, et al. Hybrid quantum-classical convolutional neural networks[J]. Science China: Physics, Mechanics & Astronomy, 2021(9): 1-8.
- [16] 王淞瑶, 张智晟. 基于量子加权GRU神经网络的电力系统短期负荷预测[J]. 电力系统及其自动化学报, 2022, 34(1): 1-7.  
(Wang S Y, Zhang Z S. Short-term load forecasting of power system based on quantum weighted GRU neural network[J]. Proceedings of the CSU-EPSA, 2022, 34(1): 1-7.)
- [17] 李锋, 向往, 王家序, 等. 基于量子加权门限重复单元神经网络的性态退化趋势预测[J]. 振动与冲击, 2019, 38(1): 123-129.  
(Li F, Xiang W, Wang J X, et al. Performance degradation trend prediction method for rotating machinery based on QWGRUNN[J]. Journal of Vibration and Shock, 2019, 38(1): 123-129.)
- [18] Zhang T T, Tang Z P, Wu J C, et al. Multi-step-ahead crude oil price forecasting based on two-layer decomposition technique and extreme learning machine optimized by the particle swarm optimization algorithm[J]. Energy, 2021, 229: 120797.
- [19] Dragomiretskiy K, Zosso D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [20] Gilles J. Empirical wavelet transform[J]. IEEE Transactions on Signal Processing, 2013, 61(16): 3999-4010.
- [21] 张金金, 张倩, 马金辉, 等. 基于EWT和LSSVM模型的短期电力负荷预测[J]. 制造业自动化, 2021, 43(1): 38-42.  
(Zhang J J, Zhang Q, Ma J H, et al. Short-term load forecasting based on EWT and LSSVM[J]. Manufacturing Automation, 2021, 43(1): 38-42.)
- [22] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [23] 邓丽, 武金达, 李科学, 等. 基于TPE的SpaRC算法超参数优化方法[J]. 计算机科学, 2021, 48(2): 70-75.  
(Deng L, Wu J D, Li K X, et al. SpaRC algorithm hyperparameter optimization methodology based on TPE[J]. Computer Science, 2021, 48(2): 70-75.)

## 作者简介

杨新彪(1998—), 男, 硕士生, 从事物流配送资源优化、深度学习等研究, E-mail: YoungXB@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;

秦娟(1976—), 女, 副教授, 博士, 从事管理决策分析、机器学习等研究, E-mail: logisticsjt@swjtu.edu.cn;

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