

引用格式:郭雪丽,华大鹏,包鹏宇,等.一种基于改进VMD-PSO-CNN-LSTM的短期电价预测方法[J].电力科学与技术学报,2024,39(2):35-43.
Citation:GUO Xueli, HUA Dapeng, BAO Pengyu, et al. A short-term electricity price forecasting method based on improved VMD-PSO-CNN-LSTM [J]. Journal of Electric Power Science and Technology, 2024, 39(2): 35-43.

一种基于改进 VMD-PSO-CNN-LSTM 的 短期电价预测方法

郭雪丽¹, 华大鹏¹, 包鹏宇², 李婷婷¹, 姚楠¹,
曹艳¹, 王莹¹, 张天东³, 胡钊³

(1. 国网河南省电力公司南阳供电公司, 河南 南阳 473000; 2. 中国电信股份有限公司湖北智能云网调度运营中心, 湖北 武汉 430022;
3. 武汉大学电气与自动化学院, 湖北 武汉 430072)

摘要: 为了提升电价预测的准确性和预测模型的稳定性, 提出一种基于改进 VMD-PSO-CNN-LSTM 的短期电价预测方法。首先, 通过研究变分模态分解 (variational mode decomposition, VMD) 与电价影响因素的相关影响程度, 并引入最大信息系数 (MIC) 构建 VMD 参数优化模型; 然后, 利用卷积神经网络 (convolutional neural networks, CNN) 与长短期记忆 (long short-term memory, LSTM) 神经网络对 VMD 分解得到的各模态分量进行预测。同时, 根据深度可分离卷积结合电价时间规律, 在 CNN 卷积部分构建多尺度的卷积特征提取结构, 并利用粒子群优化算法优化包括 CNN 卷积层数量、CNN 卷积神经元数量、LSTM 隐藏层数量、LSTM 记忆时间以及全连接层数等在内的参数, 从而实现模型预测准确性和稳定性的提升。最后, 对澳洲电力市场日前电价进行分析预测并与对照算法对比, 结果表明该文算法具有更高的精度和更好的稳定性。

关键词: 电价预测; 变分模态分解; 粒子群优化算法; 卷积神经网络; 长短期记忆神经网络

DOI: 10.19781/j.issn.1673-9140.2024.02.005 **中图分类号:** TM732 **文章编号:** 1673-9140(2024)02-0035-09

A short-term electricity price forecasting method based on improved VMD-PSO-CNN-LSTM

GUO Xueli¹, HUA Dapeng¹, BAO Pengyu², LI Tingting¹, YAO Nan¹,
CAO Yan¹, WANG Ying¹, ZHANG Tiandong³, HU Po³

(1. Nanyang Power Supply Company, State Grid Henan Electric Power Company, Nanyang 473000, China; 2. Hubei Intelligent Cloud Network Dispatching and Operation Center, China Telecom, Wuhan 430022, China; 3. School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China)

Abstract: To improve the accuracy of electricity price forecasting and the stability of forecasting models, a short-term electricity price forecasting method based on improved VMD-PSO-CNN-LSTM is proposed. Firstly, after studying the correlation between variational mode decomposition (VMD) and the influencing factors of electricity prices, and introducing the maximum information coefficient, a parameter optimization model for VMD is constructed. Secondly, convolutional neural networks (CNN) and long short-term memory (LSTM) neural networks are used to predict the modal components obtained by VMD decomposition. As for the convolution in CNN, a extraction structure with multi-scale convolution feature is constructed, on the basis of the depth-wise separable convolution combined with the time law of electricity prices. Particle swarm optimization algorithm is then used to optimize parameters including the number of CNN convolutional layers, the number of CNN convolutional neurons, the number of LSTM hidden layers, LSTM memory

收稿日期: 2023-07-05; 修回日期: 2023-10-11

基金项目: 国家自然科学基金 (51977160); 国网河南省电力公司科技项目 (SGHANY00CTJS220475)

通信作者: 华大鹏 (1973—), 男, 正高级工程师, 主要从事电力系统规划和投资管理研究; E-mail: zyhu1980@163.com

time, and the number of fully connected layers, so as to improve the prediction accuracy and stability of the model. Finally, the analysis and prediction of the day-ahead electricity prices in the Australian electricity market are carried out and compared with the algorithm. The results show that the proposed algorithm has higher accuracy and better stability.

Key words: electricity price forecast; variational modal decomposition; particle swarm optimization algorithm; convolutional neural networks; long and short time memory neural networks

随着中国电力市场化的不断推进,电价成为电力市场中最关键的因素之一,与供需关系、电能生产和人民生活等方面息息相关。为了合理预测电价的发展,已有研究主要采用统计学习预测、时间序列预测和人工神经网络预测3类方法。

在统计学习预测方面,支持向量机(support vector machine, SVM)^[1-3]是应用最广泛的方法之一,但其在短期电价预测上的准确性仍有不足。时间序列预测法主要侧重电价的时间序列特性,差分自回归滑动平均模型(auto-regressive integrated moving average model, ARIMA)^[4-8]是常用的模型,但对于非线性部分的预测精度不高,且参数较难确定。人工神经网络预测法由于深度学习的发展在电价预测上得到广泛应用,如结合卷积神经网络(convolutional neural networks, CNN)和支持向量回归(support vector regression, SVR)的CNN-SVR模型^[9]、基于Adam优化后的长短期记忆(long short-term memory, LSTM)神经网络的短期电价预测模型^[10-13]。混合模型表现出预测优势,精度不断提升。

目前,对电价短期预测的研究工作主要存在非线性部分预测准确性不高的问题。本文从预测数据分解和预测模型参数优化2个角度来优化此问题。首先,为充分发挥变分模态分解、减少数据冗余以及提取潜在特征等优势,本文引入最大互信息系数(maximum information coefficient, MIC)优化变分模态分解(variational mode decomposition, VMD)模型,将电价数据分解为不同分量;其次,利用深度可分离卷积构建并优化多尺度的卷积特征提取结构,结合电价的多时间规律优化CNN特征提取能力;最后,充分利用CNN特征提取能力结合LSTM处理变长序列能力预测电价。本文基于改进VMD分解的模态分量构建一种粒子群优化(particle swarm optimization, PSO)算法和CNN-LSTM的电价预测模型(PSO-CNN-LSTM),综合考虑纵向和横向的特征提取,利用PSO优化模型参数以提高预测稳定性和精确性。

通过这些工作,本文旨在进一步提升电价预测模型的效果,综合考虑经济和用电需求因素,提供

更准确可靠的短期电价预测。改进VMD-PSO-CNN-LSTM预测模型的逻辑结构如图1所示。此外,本文还利用深度可分离卷积构建多尺度的卷积特征提取结构,结合电价的多时间规律,进一步提高预测精度。

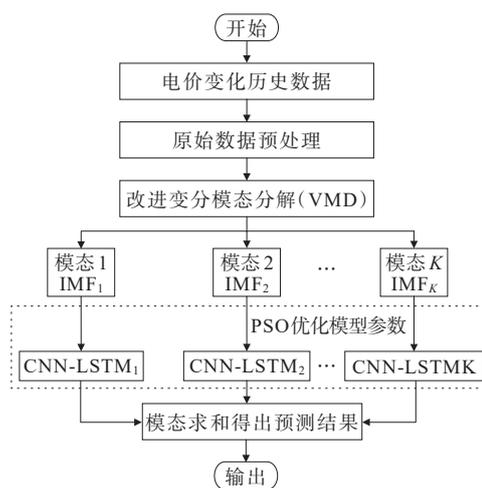


图1 改进VMD-PSO-CNN-LSTM预测模型逻辑结构

Figure 1 Logical structure of improved VMD-PSO-CNN-LSTM predictive model

1 VMD分解及改进方法

电价预测具有以下特性:①电价时序数据通常非平稳,包含趋势、周期性和噪声成分,时变动态复杂,难以准确预测;②电价受到多种因素影响,如天气、时间和供需关系等,建模难度大;③电价数据高维、信息量大,特征选择和模型设计较为困难;④电价变化快速,要求预测模型有较高精度和实时性^[14-17]。

针对此特性,利用VMD优势,即①VMD可以有效分解电价时序数据,提取其中的趋势、周期和噪声成分,减轻预测难度;针对不同成分选择适合的预测模型和特征,以提高精度;②分解后可以分别预测各个成分再进行综合,相比直接综合预测各成分,能更好把握各成分的变化规律,提高预测准确性;③可以针对高频噪声成分进行滤波,去除噪声对预测结果的影响,得到更平滑的预测曲线。

1.1 VMD分解

VMD算法是一种完全非递归的信号处理方

法,VMD的分解过程实质为变分问题的求解过程,在分解时,本征模态函数(intrinsic mode function, IMF)被定义成一种包含带宽限制的调幅—调频函数,VMD算法通过构造并求解约束变分问题,将原始信号分解为指定个数的IMF分量。

构造变分模态分解问题的目标函数及限制条件为

$$\begin{cases} \min_{\{u_i\}, \{\omega_i\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[(\delta(t) + \frac{j}{\pi t}) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \quad \sum_{k=1}^K u_k(t) = f(t) \end{cases} \quad (1)$$

式中, $u_k(t)$ 为所有模态; ω_k 为各种模态对应的中心频率。

利用交替方向乘子(alternating direction method of multipliers, ADMM)算法求解VMD模型,其具体流程如下。

1) 初始化参数。初始化模态分量 $\{u_i^1\}$ 、中心频率 $\{\omega_k^1\}$ 和拉格朗日乘子 $\{\lambda^1\}$, 并将迭代次数 k 置零。

2) 根据以下公式对IMF从1到 k 更新 u_k 和 ω_k 。

$$u_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{i < k} u_i^{n+1}(\omega) - \sum_{i > k} u_i^n(\omega) + \frac{\lambda^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (2)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |u_i^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |u_i^{n+1}(\omega)|^2 d\omega} \quad (3)$$

3) 更新拉格朗日乘子 λ 。

$$\lambda^{n+1}(\omega) = \lambda^n(\omega) + \tau \left[f(\omega) - \sum_k u_k^{n+1}(\omega) \right] \quad (4)$$

4) 判断收敛。

$$\sum_k \frac{\|u_k^{n+1} - u_k^n\|_2^2}{\|u_k^n\|_2^2} < \varepsilon \quad (5)$$

其中, $\varepsilon = 10^{-6}$ 。当判断为收敛时,循环停止,得到各IMF分量。

1.2 改进VMD

考虑VMD算法需要人为设定IMF分量的个数和惩罚因子的大小,上述初始值的设定对分解的效果影响较大,并且在后续电价预测中,需要分析各分量与影响因素的具体相关性,而且各相关性也会影响预测模型中权值的大小,因此,本文引入MIC,通过对VMD的IMF分量的个数和惩罚因子的大小参数优化来改进VMD算法,进而提升对各分量预

测的准确性^[18]。

MIC是通过计算互信息和利用网格划分的方法,衡量变量之间的相关程度,可以有效量化变量之间的线性关系或非线性关系。互信息(mutual information, MI)表达为

$$k_{MI}(A, B) = \sum_{a \in A} \sum_{b \in B} p(a, b) \log \frac{p(a, b)}{p(a)p(b)} \quad (6)$$

式中, A, B 为计算变量, $A = \{a_i, i = 1, 2, \dots, n\}$ 、 $B = \{b_i, i = 1, 2, \dots, n\}$; $p(a, b)$ 为 A, B 的联合概率密度; $p(a), p(b)$ 分别为 A, B 的边缘概率密度。

设 $D = \{(a_i, b_i), i = 1, 2, \dots, n\}$ 为 A, B 的联合有序数对集合,定义划分规则 G 将 A, B 的值域分别划分为 x, y 段,即划分为 $x \times y$ 的网格。在得到的每种网格划分内部计算互信息 $k_{MI}(A, B)$,取划分方式中 $k_{MI}(A, B)$ 的最大值即为最大互信息,其表达式为

$$k_{MI}^*(D, x, y) = \max k_{MI}(D|G) \quad (7)$$

式中, $D|G$ 为数据 D 在 G 规则下划分。

在此基础上,将不同划分规则下得到的最大归一化 $k_{MI}(A, B)$ 值组成特征矩阵,其表达式为

$$M(D)_{x,y} = \frac{k_{MI}^*(D, x, y)}{\log \min \{x, y\}} \quad (8)$$

则最大互信息系数表达式为

$$k_{MIC}(D) = \max_{x \times y < B(n)} \{M(D)_{x,y}\} \quad (9)$$

式中, $B(n)$ 为网格划分尺寸 $x \times y$ 的上限值,本文取 $B(n) = n^{0.6}$ 。

根据上述理论, $k_{MIC}(D)$ 的值越大表示变量之间的相关性越强,当 $k_{MIC}(D) = 0$ 时,变量之间相互独立。为了更好地从电价信号中得到最优分量,本文引入MIC构建VMD参数优化目标函数,其表达式为

$$\min f(K, \alpha) = \min_{j=2}^K \frac{\sum_{j=2}^K k_{MIC}[u(j-1), u(j)]}{\sum_{i=1}^L \sum_{h=1}^K k_{MIC}[u(h), Y_i]} \quad (10)$$

式中, $\sum_{j=2}^K k_{MIC}[u(j-1), u(j)]$ 为以 (K, α) 为分解参数下的相邻模态分量的MIC之和; $k_{MIC}[u(h), Y_i]$ 为各模态分量与影响因素 Y_i 的MIC。

2 PSO-CNN-LSTM预测模型构建

CNN是一种含有卷积处理并拥有深度结构的前馈神经网络^[12],具有强大的特征提取能力和非线性运算能力,进而也赋予其优秀的分类和回归能

力。CNN擅长提取时序数据的本地特征,可以自动学习电价数据中的短期模式和趋势,而LSTM擅长记忆长期依赖关系,可以捕捉电价数据的长期趋势和周期规律。两者结合可以提取多尺度的特征,对电价变化有更强的把握^[19-21]。

2.1 电价影响因素分析

由于电价变化的长、短周期性,本文考虑电价预测的影响因素,包括日前负荷、上一单位时刻的电价、实时煤炭价格、温度、湿度、单位时刻所在月份以及星期几等因素^[22]。输入变量格式如表1所示。

表1 输入变量设定

Table 1 Input variable settings

连续性变量	变量格式	离散型变量	变量格式
日前观测点负荷	1×48	星期数	1×7
日前观测点电价	1×48	月份	1×12
预测点上一时刻电价	1×48	判断是否为周末	0,1
预测点上一时刻负荷	1×48	判断节假日	0,1
预测点对应湿度	1×48	小时数	1×24
日内序列号	1×48		
煤炭价格	1×48		

2.2 CNN

CNN结构及其数据处理模拟过程如图2所示,CNN可以从原始电价数据本身中直接提取其明显特征,网络结构主要包含输入层、卷积层、池化层、全连接层和输出层^[23]。

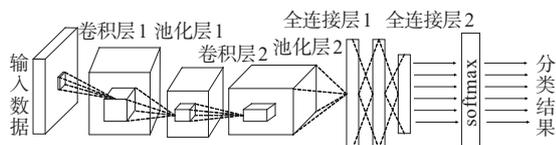


图2 卷积神经网络的结构及其数据处理模拟过程

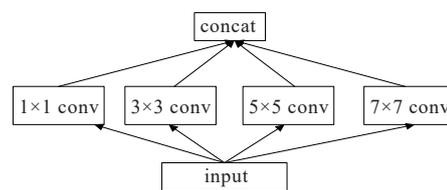
Figure 2 Structure and data processing simulation process of convolutional neural network

本文结合深度可分离卷积,提取影响电价的电价各类数据的特征量,具体的构建步骤如下。

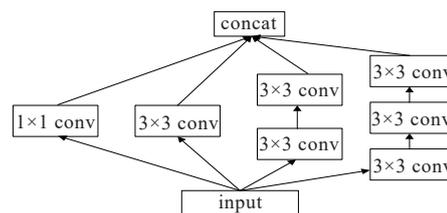
1) 结合电价时间规律,构建多维度的卷积处理,处理过程如图3所示。根据电价的周期性表现,可以对应相应的卷积层维度来提取电价的周期性特征量。特征提取思路如图3(a)所示,将特征分别用1、3、5、7尺寸的卷积感受野提取。根据卷积尺寸等价变化,可以将5、7尺寸的卷积层转化为2、3层 3×3 的卷积层代替,如图3(b)所示。

2) 利用深度可分离卷积优化卷积层。优化后的卷积层结构如图4所示。

3) 为防止网络层数增多而导致网络性能退化,本文基于优化后的卷积层,在卷积特征提取的框架上添加残差结构,卷积特征提取的整体结构如图5所示。



(a) 卷积模块不同感受野分解



(b) 感受野用 3×3 等价

图3 CNN提取电价影响因素特征结构

Figure 3 Characteristic structure extraction of factors affecting electricity price by CNN

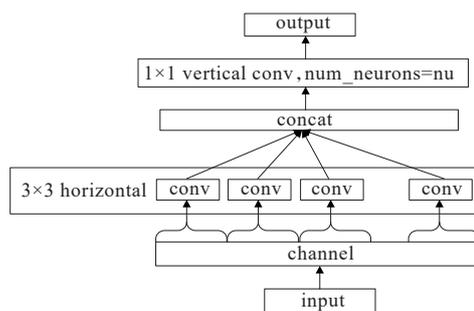


图4 CNN提取电价影响因素特征结构优化示意

Figure 4 Optimized characteristic structure extraction of factors affecting electricity price by CNN

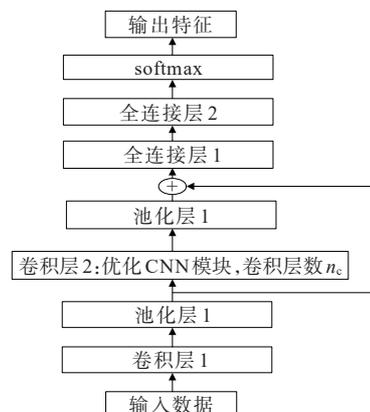


图5 改进卷积神经网络的结构

Figure 5 Improved structure of convolutional neural network

2.3 CNN-LSTM 预测算法

考虑 CNN 具有优秀的空间特征提取能力,而 LSTM 具有强大的时序特征提取能力,本文构建 CNN-LSTM 预测模型,可以从数据的纵向时间维度提取变化特征量的同时,从其横向多特征维度提取时间变化特征量。

CNN 的卷积层具有平移不变性,对时序数据的位置变化比较鲁棒,而 LSTM 的循环结构也具有这

方面的优势。因此,采用 CNN-LSTM 模型其整体也会继承这一特点,对电价数据中的噪声干扰会更为稳定。

本文将 CNN-LSTM 模型划分为 2 个过程:①利用 CNN 的卷积和池化操作提取信号中存在的空间结构信息过程;②运用 LSTM 算法将卷积结构提取到的深层次抽象特征处理为时序变化量。具体的模型构建如图 6 所示。

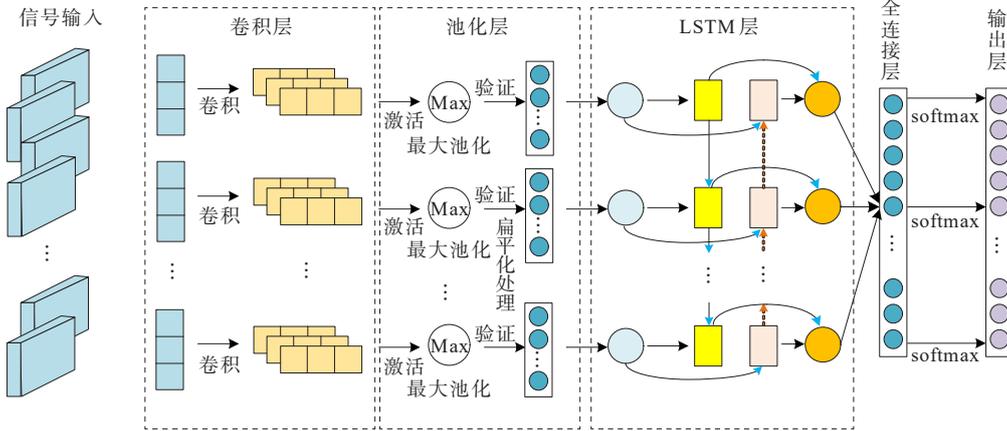


图 6 CNN-LSTM 数据迭代及逻辑结构

Figure 6 Data iteration and logical structure of CNN-LSTM

2.4 PSO 优化模型参数

在使用 CNN-LSTM 预测模型时,初始模型超参数的选择对模型预测的准确性有很大的影响,其中参数包括 CNN 卷积层数量 n_c 、CNN 卷积神经元数量 n_u 、LSTM 隐藏层数量 n_L 、LSTM 记忆时间 T_{mem} 以及全连接层数 n_d 等。选择参数时本文利用 PSO 优化模型参数^[24-26],该模型的参数逻辑如图 7 所示。

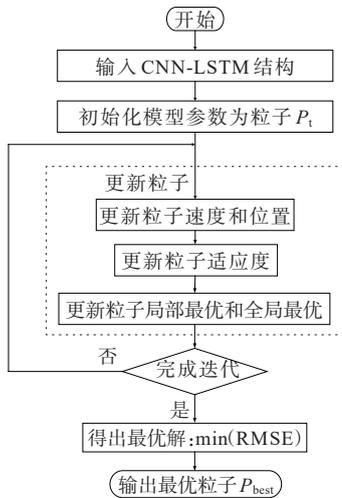


图 7 PSO 优化模型的参数逻辑结构

Figure 7 Parameter logical structure of PSO optimization model

3 实验及分析

3.1 实验数据集

本文采用澳大利亚某地区 2011 年 1 月 1 日到 2015 年 12 月 31 日的真实负荷、电价和天气等数据,验证本方法预测的性能^[27]。本研究中所有算法都基于 Python3.9 环境实现,运行环境为 Windows10 操作系统,所做的预测均为 30 min 级别的预测。

3.2 数据集分析

为直观地反应地区电价的周期性和季节变化对其影响,其年内电价变化如图 8 所示。本文引用自相关函数 (autocorrelation function, ACF)^[28] 来分析不同时间尺度下电价的自相关性。ACF 公式为

$$\rho_{x,k} = \frac{\sum_{t=1}^{n-k} (x_t - \bar{x})(x_{t+k} - \bar{x})}{\sum_{t=1}^n (x_t - \bar{x})^2} \quad (11)$$

式中, n 为总时间长度; k 为延迟时间; \bar{x} 为均值。

由式(11)可知,根据延迟的时间尺度选择不同,电价的自相关性也不尽相同,计算不同延迟时间下的电价自相关性变化规律周期为 7、30 d^[28]。根据电价变化的周期性,设置 CNN 特征提取的卷积

层为 7×7 、 5×5 及其倍数的尺寸。

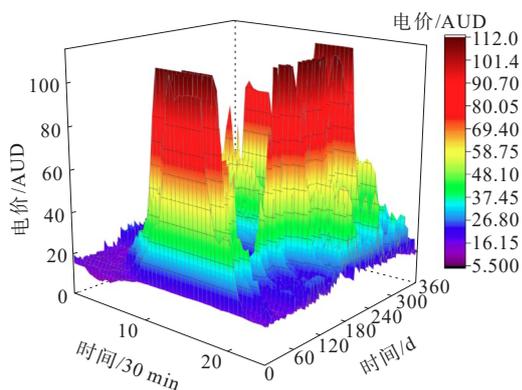


图8 年内电价变化

Figure 8 Chart of periodic changes in electricity prices

3.3 算法评价指标

根据预处理后的数据,将电力负荷和电价等相关影响因素重塑为 $48 \times a \times b$ 的三维矩阵,将其作为输入, $a \times b$ 为整合后的特征矩阵,也是输入层中的数据输入尺寸。训练的目标函数设置时以损失函数的形式衡量模型预测值与真实值在训练迭代中的差距。本文利用均方根误差(root mean square error, RMSE)作为目标函数,其公式为

$$e_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{\text{ture}} - Y_{\text{pre}})^2} \quad (12)$$

式中, Y_{ture} 、 Y_{pre} 分别为实际值和预测值; N 为预测实际值的数量。

为了客观评价模型拟合的准确性、贴合度,本文采用能反映预测性能的指标来描述模型的优劣。除RMSE外还有以下指标来描述预测模型的误差。

1) 均方误差(mean square error, MSE)。MSE可以评价数据的变化程度,MSE越小,说明预测模型描述实验数据具有更好的精确度。

$$e_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (Y_{\text{ture}} - Y_{\text{pre}})^2 \quad (13)$$

2) 平均绝对误差(mean absolute error, MAE)。

$$e_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |Y_{\text{ture}} - Y_{\text{pre}}| \quad (14)$$

3) 平均绝对百分比误差(mean absolute percent error, MAPE)。相对MAE,被比例化的MAPE更能正确地反映模型的预测精度。

$$e_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_{\text{ture}} - Y_{\text{pre}}}{Y_{\text{ture}}} \right| \times 100\% \quad (15)$$

3.4 实验结果

改进VMD考虑求解变量较少,为此运用Gurobi

9.5.0求解器求解VMD参数优化模型。改进VMD分解结果如图9所示,将电价数据经改进变分模态分解后,分成5组模态分量,根据模态分量的变化幅度、周期性不同,训练不同的预测模型对其预测。

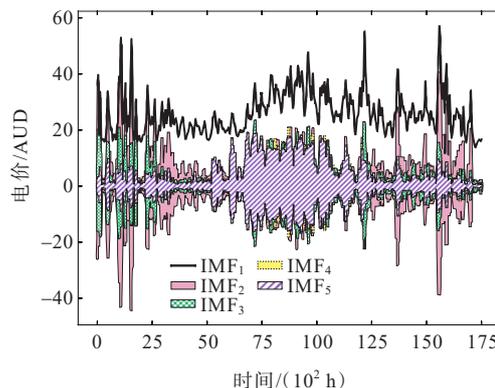


图9 改进VMD分解效果

Figure 9 Decomposition effect of improved VMD

将本文所提模型预测结果与VMD-LSTM、VMD-BP、VMD-CNN-LSTM模型预测结果进行对比(对比模型的参数可从文献[15-17]中获取)。一年中电价预测精度最高、模型最优状态下的预测情况如图10所示,各预测模型的误差分析如表2所示;一年中电价预测精度最低、模型最差状态下的预测情况如图11所示,各预测模型的误差如表3所示。

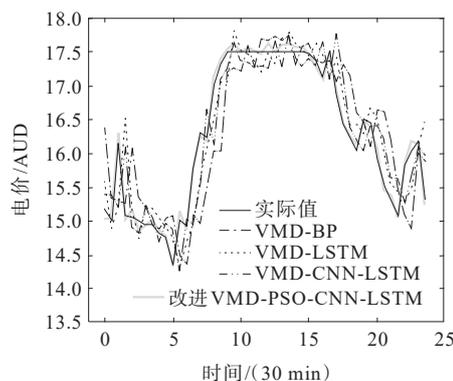


图10 模型最优预测效果

Figure 10 Effect of model optimal prediction

表2 模型最优预测下的误差

Table 2 Error of model optimal prediction

预测方法	e_{MSE}	e_{MAE}	e_{RMSE}	$e_{\text{MAPE}}/\%$
VMD-LSTM	0.231 305	0.378 902	0.480 942	2.363 654
VMD-BP	0.354 379	0.459 892	0.595 298	2.858 635
VMD-CNN-LSTM	0.190 465	0.320 230	0.436 423	2.003 505
本文预测	0.010 099	0.087 689	0.098 614	0.574 651

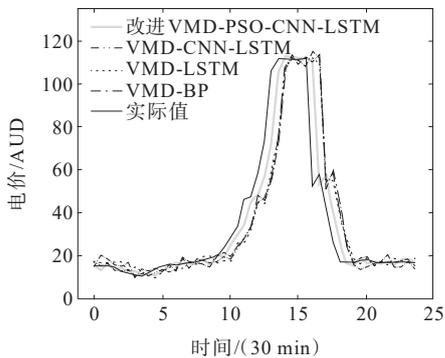


图 11 模型最差预测效果

Figure 11 Effect of model worst prediction

表 3 模型最差预测下的误差

Table 3 Error of model worst prediction

预测方法	e_{MSE}	e_{MAE}	e_{RMSE}	$e_{MAPE}/\%$
VMD-LSTM	278.167 8	8.868 627	16.678 36	24.479 20
VMD-BP	299.055 2	9.363 006	17.293 21	26.334 32
VMD-CNN-LSTM	289.478 1	9.066 184	17.014 06	25.174 62
本文预测	109.468 4	4.885 261	10.989 91	12.576 35

各模型在不同季节下的平均误差如表 4 所示;各预测方法在同季节下的平均 MAPE 柱状图如图 12 所示。

表 4 不同季节下各模型预测的误差

Table 4 Forecast error of each model in different seasons

预测方法	春季				夏季			
	e_{MSE}	e_{MAE}	e_{RMSE}	$e_{MAPE}/\%$	e_{MSE}	e_{MAE}	e_{RMSE}	$e_{MAPE}/\%$
VMD-LSTM	0.772 559	1.265 533	1.606346	7.894 604	1.357 760	2.224 155	2.823 128	13.874 650
VMD-BP	1.183 627	1.536 041	1.988 295	9.547 840	2.197 153	2.851 333	3.690 846	17.723 530
VMD-CNN-LSTM	0.636 154	1.069 570	1.457 654	6.691 707	0.609 489	1.024 737	1.396 554	6.411 217
本文预测	0.023 677	0.191 770	0.217 611	1.188 222	0.026 045	0.210 947	0.239 372	1.307 044
预测方法	秋季				冬季			
	e_{MSE}	e_{MAE}	e_{RMSE}	$e_{MAPE}/\%$	e_{MSE}	e_{MAE}	e_{RMSE}	$e_{MAPE}/\%$
VMD-LSTM	1.480 352	2.424 973	3.078 028	15.127 390	0.555 132	0.909 365	1.154 260	5.672 769
VMD-BP	1.134 014	1.471 656	1.904 953	9.147 631	0.850 511	1.103 742	1.428 715	6.860 723
VMD-CNN-LSTM	0.419 023	0.704 507	0.960 131	4.407 711	0.380 930	0.640 461	0.872 846	4.007 010
本文预测	0.021 309	0.172 593	0.195 850	1.069 399	0.017 758	0.143 828	0.163 208	0.891 166

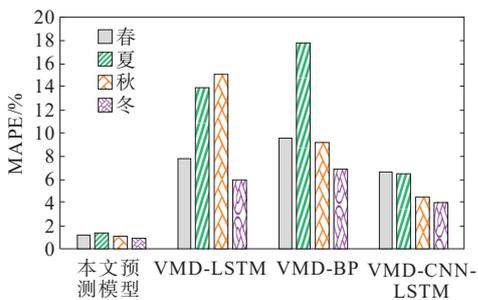


图 12 各预测方法在同季节下的平均 MAPE 柱状图

Figure 12 Average MAPE histogram of each forecasting method in the same season

由上述实验结果可知,本文提出的预测方法在周期性规律强和弱的典型日都表现出优于其他方法的预测效果,在非线性部分的预测准确性也强于其他对比方法。本文提出的预测方法在冬、夏季的典型季节预测上,也表现出与其他方法相比更准确的预测效果。

由上述分析可知,对于澳洲电价数据的预测,

本文提出的改进 VMD-PSO-CNN-LSTM 算法的稳定性和准确性都优于 VMD-LSTM、VMD-BP 和 VMD-CNN-LSTM 等算法的预测效果。

4 结语

本文提出一种基于改进 VMD-PSO-CNN-LSTM 的电价预测算法。首先,通过研究不同时间尺度下电价的影响因素,以及分析电价在不同时间、不同影响因素下的变化情况,收集与电价相关的影响因素数据。然后,通过研究变分模态分解与电价预测模型的相关影响程度,从优化变分模态分解参数选取的角度提升模态分量的预测精度,进而通过引入 MIC 构建 VMD 参数优化模型。

结合改进 VMD 分解模态分量,本文提出构建一种 PSO-CNN-LSTM 电价预测算法模型。利用 LSTM 从数据的纵向时间维度提取变化特征量的同时,考虑 CNN 从其横向多特征维度提取时间变化特征量;并利用 PSO 算法优化 CNN-LSTM 中包

括CNN卷积层数量、CNN卷积神经元数量、LSTM隐藏层数量、LSTM记忆时间以及全连接层数等模型参数,在CNN卷积部分,本文根据深度可分离卷积结合电价时间规律,构建多维度的卷积特征提取结构,以确保模型预测的稳定性和精确性。

在预测精度和预测模型稳定性上,本文通过与VMD-LSTM、VMD-BP和VMD-CNN-LSTM等算法的预测效果对比得出结论,在澳洲电价预测上有明显的优势。目前,中国电力现货市场开始在多省试点运营,然而电力市场仍然处于起步阶段,并且由于国情不同,电价的影响因素与国外相比也有所差异。国外电力市场较为成熟,电价变化的规律性也较为凸显,通过使用改进的VMD-PSO-CNN-LSTM算法对澳洲电价数据进行预测分析,为电价预测研究提供了新的方法和思路,也为今后中国电价预测方法提供了参考。

参考文献:

- [1] 徐浩,姜新雄,刘志成,等.基于概率预测的电网静态安全运行风险评估及主动调控策略[J].电力系统自动化,2022,46(1):182-191.
XU Hao, JIANG Xinxiong, LIU Zhicheng, et al. Risk assessment and active regulation strategy for static safety operation of power grids based on probability prediction[J]. Automation of Electric Power Systems, 2022,46(1):182-191.
- [2] 张健,张钦,黄晓艳,等.基于加速退化数据和现场实测退化数据的电机绝缘剩余寿命预测模型[J].电工技术学报,2023,38(3):599-609.
ZHANG Jian, ZHANG Qin, HUANG Xiaoyan, et al. A prediction model for the remaining life of motor insulation based on accelerated degradation data and on-site measured degradation data[J]. Transactions of China Electrotechnical Society, 2023,38(3):599-609.
- [3] 王文婷,安爱民,保承家,等.基于改进代价敏感直推式支持向量机的发电企业滥用市场力识别[J].电力系统保护与控制,2022,50(11):102-111.
WANG Wenting, AN Aimin, BAO Chengjia, et al. Identification of abuse of market power in power generation enterprises based on improved cost sensitive direct push support vector machine[J]. Power System Protection and Control, 2022,50(11):102-111.
- [4] 崔瑶,裴培,黄鑫,等.基于混合深度学习的调度数据网流量预测技术研究[J].供用电,2023,40(5):53-60.
CUI Yao, PEI Pei, HUANG Xin, et al. Research on traffic prediction technology of dispatching data network based on a hybrid deep learning algorithm[J]. Distribution & Utilization, 2023,40(5):53-60.
- [5] 闫红艳, Hwang Jin Kwon, 高艳丰.基于类噪声数据的电力系统低频振荡模态参数辨识[J].发电技术,2022,43(1):19-31.
YAN Hongyan, Hwang Jin Kwon, GAO Yanfeng. Identification of low-frequency oscillation modal parameters in power systems based on class noise data [J]. Power Generation Technology, 2022,43(1):19-31.
- [6] 孙浩,万灿,曹照静,等.基于条件生成对抗网络曲线生成的短期负荷概率预测[J].电力系统自动化,2023,47(23):189-199.
SUN Hao, WAN Can, CAO Zhaojing, et al. Short-term load probabilistic forecasting based on conditional generative adversarial network curve generation[J]. Automation of Electric Power Systems, 2023,47(23):189-199.
- [7] AL-MUSAYLH M S, DEO R C, ADAMOWSKI J F, et al. Short-term electricity demand forecasting with MARS, SVR and ARIMA models using aggregated demand data in Queensland Australia[J]. Advanced Engineering Informatics, 2018, 35:1-16.
- [8] HUA Z Q, XUE D M. ARIMA based time series forecasting model[J]. Recent Advances in Electrical & Electronic Engineering, 2016, 9(2):93-98.
- [9] 罗凤章,张旭,杨欣,等.基于深度学习的综合能源配电系统负荷分析预测[J].高压电压技术,2021,47(1):23-32.
LUO Fengzhang, ZHANG Xu, YANG Xin, et al. Load analysis and prediction of integrated energy distribution system based on deep learning[J]. High Voltage Engineering, 2021, 47(1):23-32.
- [10] CHANG Z, ZHANG Y, CHEN W. Effective adam-optimized LSTM neural network for electricity price forecasting[C]//IEEE 9th International Conference on Software Engineering and Service Sciences(ICSESS), Beijing, China, 2018.
- [11] 罗家林,陈超,黄梅,等.弱电网矿区下构网型储能控制技术[J].高压电器,2023,59(7):95-103.
LUO Jialin, CHEN Chao, HUANG Mei, et al. Research on energy storage control technology for underneath construction of weak current grid mining area[J]. High Voltage Apparatus, 2023,59(7):95-103.
- [12] 陈先昌.基于卷积神经网络的深度学习算法与应用研究[D].杭州:浙江工商大学,2014.
CHEN Xianchang. Research on algorithm and application of deep learning based on convolutional neural network[D]. Hangzhou: Zhejiang Gongshang University, 2014.
- [13] 朱继忠,苗雨旺,董朝阳,等.基于Attention-LSTM与多模型集成的短期负荷预测方法[J].电力工程技术,2023,42(5):138-147.
ZHU Jizhong, MIAO Yuwang, DONG Chaoyang, et al. Short term load forecasting method based on Attention-

- LSTM and multi model integration[J]. *Electric Power Engineering Technology*,2023,42(5):138-147.
- [14] ZHENG J, XU C, ZHANG Z, et al. Electric load forecasting in smart grids using long-short-term-memory based recurrent neural network[J]. 51st Annual Conference on Information Sciences and Systems (CISS), Baltimore, MD, USA, 2017.
- [15] 张运洲,陈宁,黄碧斌,等.基于系统成本的新能源等效上网电价计算方法及应用[J]. *中国电力*,2022,55(2):1-8. ZHANG Yunzhou, CHEN Ning, HUANG Bibin, et al. Calculation method and application of equivalent grid electricity price for new energy based on system cost[J]. *Electric Power*,2022,55(2):1-8.
- [16] 葛晓琳,居兴,王定美.考虑需求响应不确定性的主动配电网优化调度[J]. *电测与仪表*,2023,60(1):104-110. GE Xiaolin, JU Xing, WANG Dingmei. Active distribution network optimization scheduling considering demand response uncertainty[J]. *Electrical Measurement & Instrumentation*,2023,60(1):104-110.
- [17] 包苑村,解建仓,罗军刚.基于VMD-CNN-LSTM模型的渭河流域月径流预测[J]. *西安理工大学学报*,2021,37(1):1-8. BAO Yuancun, XIE Jiancang, LUO Jungang. Monthly runoff prediction of Weihe river basin based on VMD-CNN-LSTM model[J]. *Journal of Xi'an University of Technology*,2021,37(1):1-8.
- [18] 赵雅雪,王旭,蒋传文,等.基于最大信息系数相关性分析和改进多层级门控LSTM的短期电价预测方法[J]. *中国电机工程学报*,2021,41(1):135-146+404. ZHAO Yaxue, WANG Xu, JIANG Chuanwen, et al. A novel short-term electricity price forecasting method based on correlation analysis with the maximal information coefficient and modified multi-hierarchy gated LSTM[J]. *Proceedings of the CSEE*,2021,41(1):135-146+404.
- [19] 韩升科,胡飞虎,陈之腾,等.基于GCN-LSTM的日前市场边际电价预测[J]. *中国电机工程学报*,2022,42(09):3276-3286. HAN Shengke, HU Feihu, CHEN Zhiteng, et al. Advance market marginal electricity price forecast based on GCN-LSTM[J]. *Proceedings of the CSEE*,2022,42(9):3276-3286.
- [20] 廖雪超,陈才圣,伍杰平.基于CNN-LSTM及深度学习的风电场时空组合预测模型[J]. *信息与控制*,2022,51(4):498-512. LIAO Xuechao, CHEN Caisheng, WU Jieping. Space-time Combined spatiotemporal wind farm prediction model based on CNN-LSTM and deep learning[J]. *Information and Control*,2022,51(4):498-512.
- [21] 陈海鹏,周越豪,王趁录,等.基于改进的CNN-LSTM短期风功率预测的系统旋转备用经济性分析[J]. *高电压技术*,2022,48(2):439-448. CHEN Haipeng, ZHOU Yuehao, WANG Chenlu, et al. Economic analysis of system spinning reserve based on improved CNN-LSTM short-term wind power prediction [J]. *High Voltage Technology*,2022,48(2):439-448.
- [22] 赵佩,代业明.基于实时电价和加权灰色关联投影的SVM电力负荷预测[J]. *电网技术*,2020,44(4):1325-1332. ZHAO Pei, DAI Yeming. Power load forecasting of SVM based on real-time price and weighted grey relational projection algorithm[J]. *Power System Technology*,2020,44(4):1325-1332.
- [23] 朱凌建,荀子涵,王裕鑫,等.基于CNN-BiLSTM的短期电力负荷预测[J]. *电网技术*,2021,45(11):4532-4539. ZHU Lingjian, XUN Zihan, WANG Yuxin, et al. Short-term power load forecasting based on CNN-BiLSTM[J]. *Power System Technology*,2021,45(11):4532-4539.
- [24] 袁建华,谢斌斌,何宝林,等.基于DTW-VMD-PSO-BP的光伏发电功率短期预测方法[J]. *太阳能学报*,2022,43(8):58-66. YUAN Jianhua, XIE Binbin, HE Baolin, et al. Short-term forecasting method of photovoltaic output based on DTW-VMD-PSO-BP[J]. *Acta Energetica Solaris Sinica*,2022,43(8):58-66.
- [25] 孙广路,宋智超,刘金来,等.基于最大信息系数和近似马尔科夫链的特征选择方法[J]. *自动化学报*,2017,43(5):795-805. SUN Guanglu, SONG Zhichao, LIU Jinlai, et al. Feature selection method based on maximum information coefficient and approximate Markov blanket[J]. *Acta Automation Sinica*,2017,43(5):795-805.
- [26] 殷豪,丁伟锋,陈顺,等.基于长时记忆网络—纵横交叉算法的含高比例新能源电力市场日前电价预测[J]. *电网技术*,2022,46(2):472-480. YIN Hao, DING Weifeng, CHEN Shun, et al. Day-ahead electricity price forecasting of electricity market with high proportion of new energy based on LSTM-CSO model[J]. *Power System Technology*,2022,46(2):472-480.
- [27] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]//IEEE Conference on Computer Vision and Pattern Recognition(CVPR), Honolulu, HI, USA,2017.
- [28] 温露露.能源互联网环境下基于负荷特征的需求响应策略研究[D].合肥:合肥工业大学,2021. WEN Lulu. Research on demand response strategy based on load characteristics in the environment of energy Internet[D]. Hefei: Hefei University of Technology,2021.