信息与控制　2024 年　第 53 卷　第 2 期：238 ~ 249

DOI：10.13976/j.cnki.xk.2024.3021　　文章编号：1002 - 0411(2024) - 02 - 0238 - 12

基于 VMD-CNN-LSTM 的农业大棚园区用电负荷短期预测

张培霄[1]，尹晓红[1]，李少远[1]，王新立[2]

1. 青岛科技大学自动化与电子工程学院，山东 青岛　266061；
2. 山东大学控制科学与工程学院，山东 济南　250061

基金项目：国家自然科学基金项目(61703223)；山东省重点研发计划重大科技创新工程项目(2020CXGC011402)
通信作者：尹晓红，yxh@qust.edu.cn
收稿/录用/修回：2023 - 02 - 06/2023 - 05 - 15/2023 - 09 - 08

摘要

针对农业大棚用电负荷受农村供电能力、气象因素等的影响，具有强波动性和高非线性的问题，综合大棚短期负荷的气象特征和时序特征，提出了一种基于变分模态分解(variational mode decomposition，VMD)的长短期记忆(long short-term memory，LSTM)网络与卷积神经网络(convolutional neural network，CNN)相融合的 VMD-CNN-LSTM 的短期负荷预测模型架构。首先，基于 VMD 方法分解负荷序列，降低负荷波动性；其次，采用 CNN 方法提取负荷的气象特征，采用 LSTM 方法提取负荷时序特征，进行负荷分量预测，并将模态分量的预测结果重构；最后，以山东省寿光市农业大棚负荷数据为基础开展仿真实验。结果表明，VMD-CNN-LSTM 模型与传统神经网络模型相比，可有效提高农业大棚短期负荷预测的精度。

关键词

农业大棚园区负荷
变分模态分解
短期负荷预测
卷积神经网络
长短期记忆网络

中图法分类号： TM715
文献标志码： A

The Short-term Forecasting of Power Load in Agricultural Greenhouses Based on VMD-CNN-LSTM

ZHANG Peixiao[1], YIN Xiaohong[1], LI Shaoyuan[1], WANG Xinli[2]

1. *School of Automation and Electronic Engineering*, *Qingdao University of Science and Technology*, *Qingdao* 266061, *China*;
2. *School of Control Science and Engineering*, *Shandong University*, *Jinan* 250061, *China*

Abstract

Based on the meteorological and temporal characteristics of short-term load in greenhouses, an integrated short-term load prediction architecture based on the fusion of variational mode decomposition (VMD), convolutional neural network (CNN), and long short-term memory (LSTM) is proposed to solve the problem that the electricity load of agricultural greenhouses is affected by rural power supply capacity and meteorological factors, which have strong fluctuation and high nonlinear characteristics. First, the load sequence is decomposed using the VMD method to reduce load volatility. Second, the meteorological characteristics of the load are extracted using the CNN method, and the temporal characteristics of the load are extracted using the LSTM method. Component prediction is performed, and the prediction results of the model components are reconstructed. Finally, based on the load data of agricultural greenhouses in Shouguang, Shandong Province, the experimental results show that compared with the traditional neural network model, the proposed VMD-CNN-LSTM model can effectively improve the precision of short-term load prediction of agricultural greenhouses.

Keywords

agricultural greenhouse park load;
variational mode decomposition;
short-term load forecasting;
convolutional neural network;
long short-term memory network

0　引言

随着人们生活水平的提高，农业大棚的负荷需求日益攀升，然而农村电网系统存在智能化、自动化水平低，基础设施薄弱，供电能力不足等问题，亟需合理准确地对农业大棚的负荷进行预测，提供未来大棚需求的负荷数据，优化能源配置，保证农业大棚用电的安全性和可靠性。

负荷预测可划分为长期负荷预测、中期负荷预测、短期负荷预测和超短期负荷预测。其中短期负荷预测指 1 年内以天或小时为单位的负荷变化情况预测，可实时预测未来时间尺度的用电负荷[1]。负荷预测的常用方法包括：用电单耗法、年平均增长率法、系数法和典型模式组合法等。上述方法将负荷作为数据标量进行预测，而忽视了其内在的规律性或其它影响因素，预测的效果不理想。此外，电力系统还采用弹性系数法、回归分析法[2]、灰色预测法[3]等方法进行负荷预测。然而以上方法对于数据的要求过高，缺乏自适应能力且预测鲁棒性较差，难以反映非线性的影响因素。

随着神经网络和机器学习的发展，针对用电负荷的新型智能预测方法得到了进一步研究[4]。为了兼顾数据的时序性和非线性关系，文[5]开发基于循环神经网络(recurrent neural network，RNN)的电力系统负荷预测模型，该模型可预测更长的历史数据序列并准确映射负荷影响因素与负荷间复杂的非线性关系。文[6－7]提出基于长短时记忆(long short-term memory，LSTM)网络的配电网线路的负荷预测模型，解决了 RNN 在长序列训练中容易出现梯度消失的问题。文[8]开发了基于卷积神经网络(convolutional neural network，CNN)和门控循环单元(gate recurrent unit，GRU)的配电网短期负荷预测模型，利用 CNN 提取负荷序列空间特征的优点，解决了负荷受到复杂因素影响的问题。为了解决在实际中，短期负荷序列的非线性强、波动大、严重影响预测准确性的问题，康义等[9]提出了小波变换(wavelet transform，WT)、改进粒子群算法(improved particle swarm optimization，IPSO)和 BP 神经网络相结合的预测模型架构，得到更高精度的预测结果。此外，LIU 等[10]学者采用经验模态分解方法(empirical mode decomposition，EMD)，将负荷序列分解成多个平滑序列，结合支持向量回归(support vector regression，SVR)[11]方法逐个预测，最终将序列重组，结果表明，对负荷序列进行分解重组处理可以得到更精准的预测序列。文[12]采用变分模态分解对海上风电场的风速序列进行预处理，使用粒子群算法(particle swarm optimization，PSO)[13]优化双向长短期记忆网络(bidirectional short and long term memory network，Bi-LSTM)[14]模型参数，对每组模态分量进行预测，降低了序列的非平稳性。以上研究均取得了较好的负荷预测精度，然而针对农村综合能源系统特性情况下农业大棚的准确负荷预测仍然欠缺。

本文针对农村用电负荷波动大、受气象因素影响较大和时序特点明显的特性，提出基于 VMD 分解的 CNN-LSTM 新型农村农业大棚短期负荷预测模型。首先，通过 VMD 分解将负荷序列分解成 8 组序列，减少原始序列的波动，使序列平滑化。其次，采用 CNN 方法提取数据的空间特征[15]，通过卷积、池化形成新的时间序列数据。针对负荷序列的时序特点采用 LSTM 方法提取时序特征，对负荷进行预测。最后，将 8 组预测后的序列重构，得到预测序列，通过仿真计算与对比分析[16]，验证了文中所提预测模型的高效性与精确性。

1　农业大棚用电负荷特性分析

农业大棚通过保温电机、水平循环风扇和供液泵等设备对大棚内温度、湿度等条件的调控实现农作物质量和产量的提高。由于大棚外部天气的不确定性，维持大棚内部环境在不同时刻的稳定状态，导致大棚用电负荷具有高非线性和强波动性。图 1 为山东省蔬菜之乡寿光市某农业大棚园区每小时的用电数据，如图所示农业大棚用电负荷最高峰可以达到 150 kW，最低只有 70 kW，大棚用电负荷具有非线性高、波动性强的特点。此外，大棚受外部天气不确定性的影响较大，外部气温降低时用电负荷需求增加，外部温度升高时用电负荷需求减少。因此，维持大棚内部环境在不同时刻的稳定状态，节约大棚用电能耗，亟需准确的用电负荷预测。

2　基于 VMD-CNN-LSTM 的短期负荷预测策略

2.1　预测模型架构

针对农业大棚用电特点，本文设计基于变分模态分解和时空网络(VMD-CNN-LSTM)的短期负荷预测模型，如图 2 所示。VMD-CNN-LSTM 的模型架构主要包括 4 层：输入层、CNN 层、LSTM 层和输出层。在输入层中，使用 VMD 将历史负荷数据分

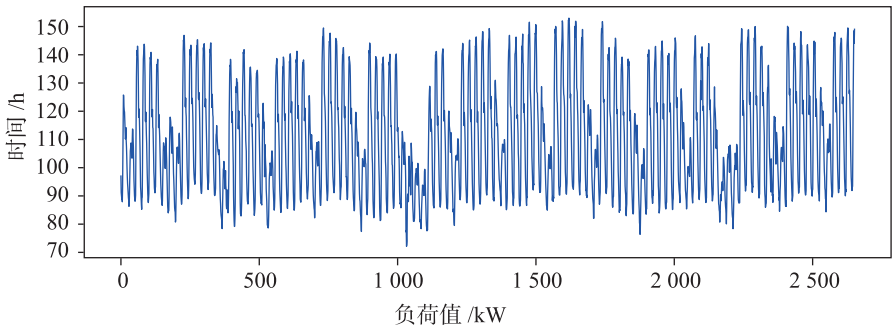

图 1　农业大棚用电负荷曲线

Fig.1　Electricity load curve of agricultural greenhouses

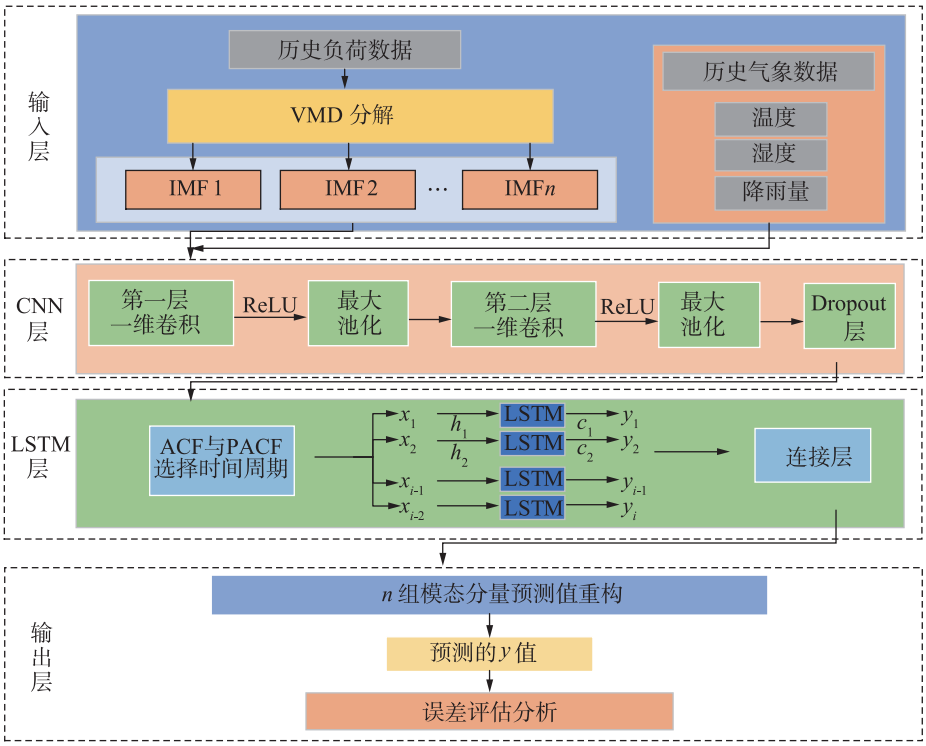

图 2　负荷预测模型架构

Fig.2　Load forecasting model architecture

解为多组模态分量(intrinsic mode function, IMF),减少序列波动对负荷预测的影响,并将历史气象数据与每组模态分量组合,作为 CNN 层输入数据。在 CNN 层,输入矩阵和特定卷积核进行一维卷积池化操作,分析负荷序列中温度、湿度和降雨量这 3 种气候序列与负荷序列之间的相关性,并使用 Dropout 层,避免过拟合效应。在 LSTM 层中,将 CNN 层输出的实数向量作为输入,采用自相关函数(AutoCorrelation Function, ACF)和偏自相关函数(Partial AutoCorrelation Function, PACF)分析历史值与当前值的自相关性,利用 LSTM 的记忆性提取序列的时序特征。在输出层中,将所有序列分量的负荷预测值进行重构,并对预测结果进行误差评估分析。

2.2　负荷数据分解

农业大棚电力负荷数据具有强波动性,严重影响预测模型的精度,本文采用 VMD 方法对负荷序列进行分解,使序列平滑化。VMD 是一种自适应、完全非递归的模态变分和信号处理的方法[17],利用迭代求解最优变分模型来确定各分解分量的中心频率及带宽,构建模态函数,逐步将各模态(IMF)解调到相应的基频带,有效降低高复杂度和强非线性的时间序列非平稳性,提高对噪声的鲁棒性。

构造变分问题,假设原始信号是 $f(t)$,相应的约束变分表达式如式(1)所示:

$$\min_{\{u_k\},\{\omega_k\}}\left\{\sum_k\left\|\partial_t\left[\left(\delta(t)+\frac{j}{\pi t}\right)\times u_k(t)\right]e^{-j\omega_k t}\right\|_2^2\right\}$$

$$\text{s.t.}\sum_k^K u_k=f(t) \tag{1}$$

其中，u_k 为第 k 个模态的模态函数，ω_k 为第 k 个模态的中心频率，K 为分解后模态个数，δ 为狄拉克分布，∂_t 为求偏导符号。

u_k 和 ω_k 作为约束条件，利用二次惩罚项和拉格朗日乘子法将约束变分问题转变为非约束变分问题，引入增广拉格朗日函数，如式(2)所示：

$$\begin{aligned}&L(\{u_k\},\{\omega_k\},\lambda)\\&=\alpha\sum_k\left\|\partial_t\left[\left(\delta(t)+\frac{j}{\pi t}\right)\times u_k(t)\right]e^{-j\omega_k t}\right\|_2^2+\\&\left\|f(t)-\sum_k u_k(t)\right\|_2^2+\left(\lambda(t),f(t)-\sum_k u_k(t)\right)\end{aligned} \tag{2}$$

其中，α 为惩罚因子，保证信号重构后的准确性；λ 为拉格朗日乘子，保持约束条件的严格性。

更新约束参数，寻找式(2)的鞍点，首先将 u_k、ω_k、λ 和 n 初始化，根据式(3)～式(5)更新得到 u_k^{n+1}、ω_k^{n+1} 和 λ^{n+1}，直到满足式(6)的迭代约束条件。

$$\hat{u}_k^{n+1}(\omega)=\frac{\hat{f}(\omega)-\sum_{i=1,i<k}^{K}\hat{u}_i(\omega)+\hat{\lambda}(\omega)/2}{1+2\alpha(\omega-\omega_k)^2} \tag{3}$$

$$\omega_k^{n+1}=\frac{\int_0^\infty\omega|\hat{u}(\omega)|^2}{\int_0^\infty|\hat{u}(\omega)|^2} \tag{4}$$

$$\hat{\lambda}^{n+1}(\omega)=\hat{\lambda}^n(\omega)+\tau\left(\hat{f}(\omega)-\sum_{k=1}^K\hat{u}_k^{n+1}(\omega)\right) \tag{5}$$

$$\sum_{k=1}^K\frac{u_k^{n+1}-u_{k2}^{n2}}{u_{k2}^{n2}}<\varepsilon \tag{6}$$

其中，τ 为噪声容限，$\varepsilon>0$ 为收敛依据。

2.3　负荷气象特征提取

负荷受气候因素的影响较大，本文通过 CNN 方法对气象序列与负荷序列之间的相关性进行分析[18-19]，提取负荷的气象特征。CNN 层主要由卷积层、池化层和 Dropout 层组成。

将气象序列与经过模态分解后的子序列作为输入的特征序列，卷积层将特征序列与卷积核进行卷积得到多组特征向量，卷积层的处理如式(7)，随后输入到池化层进行最大池化操作，将池化后的特征向量输入 Dropout 层，减少每次迭代中对局部特征的依赖，减弱过拟合效应如式(8)所示。最终将特征向量进行降维并按时域顺序组成实数向量，这些向量保留了各特征值与负荷子序列空间特性，并作为 LSTM 层的输入。

$$\boldsymbol{w}_{i+1}=f\left(\sum_i\boldsymbol{w}_i\boldsymbol{x}_i+b\right) \tag{7}$$

其中，$\boldsymbol{w}_{i+1}$ 为第 $i+1$ 层的权重，$\boldsymbol{w}_i$ 为第 i 层的权重；b 为偏置量；$\boldsymbol{x}_i$ 为第 i 个样本；f 为 ReLU 激活函数，选择 ReLU 激活函数可以保证输入数据上的稀疏性同时避免梯度消失的问题。

$$\begin{aligned}r_i&=\text{Bernoulli}(p)\\\tilde{y}_i&=r_iy_i\end{aligned} \tag{8}$$

其中，Bernoulli 为伯努利分布，p 为随机抽取的概率，r_i 为一个在 0 到 1 之间的概率随机值，y_i 为当前层的输出，$\tilde{y}_i$ 为新的输出。

2.4　负荷时序特征提取

本文使用的大棚负荷序列较长并且具有强时序性，历史负荷数据可为负荷预测提供依据。GRU 和 LSTM 都可有效提取数据中的时序特征，解决长序列训练过程中的梯度消失和梯度爆炸问题。它们在不同任务中的表现略有不同。一般来说，处理长序列数据，LSTM 的性能略优于 GRU[20]。LSTM 内部结构如图 3 所示，其中，c^t 为细胞状态，h^t 为隐藏状态，z^f，z^i，z^o 如式(9)～式(11)是 LSTM 内部的 3 种门控状态，分别对应遗忘门，输入门和输出门，z 是将结果通过激活函数转换后的值。

将 CNN 层输出的实数向量作为 LSTM 的输入，并在全连接层对 LSTM 隐藏层的输出进行加权求和，得到负荷的时序特征。

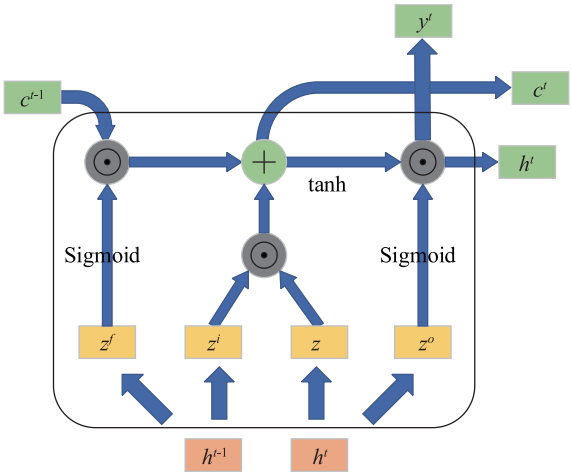

图 3　LSTM 结构图

Fig.3　Structure diagram of LSTM

$$z^f=\sigma(\boldsymbol{W}^f\otimes[\boldsymbol{x}^t,\boldsymbol{h}^{t-1}]) \tag{9}$$

$$z^i=\sigma(\boldsymbol{W}^i\otimes[\boldsymbol{x}^t,\boldsymbol{h}^{t-1}]) \tag{10}$$

$$z^o=\sigma(\boldsymbol{W}^o\otimes[\boldsymbol{x}^t,\boldsymbol{h}^{t-1}]) \tag{11}$$

其中，⊗表示操作矩阵中元素相乘，$\boldsymbol{W}^f$、$\boldsymbol{W}^i$ 和 $\boldsymbol{W}^o$ 分别为遗忘门、输入门和输出门的权重系数，$\boldsymbol{x}^t$ 为当前神经元的输入，$\boldsymbol{h}^{t-1}$为上一个神经元的隐藏状态。

2.5 基于 ACF/PACF 的时间周期

ACF 和 PACF 是描述时间序列中当前值和历史值相关性的自相关函数和偏自相关函数，公式如式(12)、式(13)所示，具有两种状态：截尾与拖尾。截尾是指 ACF 或 PACF 在某阶过后均为 0 的性质，拖尾指两者并不在某阶后均为 0 的性质。本文基于 ACF 和 PACF 函数得到 LSTM 预测模型中向量的历史窗口长度。

$$\text{ACF}: \rho_k = \frac{\sum_{t=1}^{n}(O_t - \overline{O})(O_{t-k} - \overline{O})}{\sum_{t=1}^{n}(O_t - \overline{O})^2} \tag{12}$$

$$\text{PACF}: \varphi_k = \frac{\rho_k - \sum_{j=1}^{k-1}\varphi_{k-1,j}\rho_{k-j}}{1 - \sum_{j=1}^{k-1}\varphi_{k-1,j}\rho_j} \tag{13}$$

其中，ρ_k 是滞后 k 阶的 ACF，O_t 是 t 时刻的观察值，O_{t-k}是 $t-k$ 时刻的观察值，$\overline{O}$ 是时间序列 O 的平均值，k 表示滞后的阶数，φ_k 是滞后 k 阶的 PACF。

使用自回归模型和移动平均模型对数据进行平稳性处理。

2.6 评估标准

对于负荷预测的评估问题[21]，本文选择统计指标均方根误差(RMSE)、平均绝对百分比误差(MAPE)和平均绝对误差(MAE)来评估和比较回归精度，取值越小，精度越高。它们在方程式(14)~(16)中定义如下：

$$\text{RMSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(\hat{S}_i - S_i)^2} \tag{14}$$

$$\text{MAE} = \frac{1}{n}\sum_{i=1}^{n}|\hat{S}_i - S_i| \tag{15}$$

$$\text{MAPE} = \frac{100\%}{n}\sum_{i=1}^{n}\left|\frac{\hat{S}_i - S_i}{S_i}\right| \tag{16}$$

其中，$\hat{S}_i$ 是 i 时的实际负荷值，S_i 是 i 时的预测负荷值。

3 实验与讨论

3.1 实验设置

3.1.1 实验说明

本文使用的实验平台为 Windows10 X64 操作系统、Inter i5-11400 CPU，提出的预测模型使用 Python 语言编程实现，CNN 和 LSTM 算法采用 keras 框架。

CNN 卷积核的大小和数量分别为 2×2 和 80，池化层为最大池化，全连接层的激活函数为 ReLU。在选择 LSTM 参数时，首先确定 LSTM 的层数，设置每层神经元的个数为 64，分别将 LSTM 层数设置 1 层、2 层、3 层、4 层进行检测实验，实验结果如表 1 所示。

表 1 不同 LSTM 层数实验结果

Tab.1 Experiment results with different LSTM layer numbers

单位：kW

统计指标	1 层	2 层	3 层	4 层
RMSE	2.717	2.568	2.986	3.148
MAE	2.043	1.878	2.238	2.501

分析实验结果可知，LSTM 层数选择为 2 时，RMSE 指标值和 MAE 指标值均为最小，综合实验结果，选择将 LSTM 的层数设置为 2。确定 LSTM 层数后，再确定每层的神经元数，分别设置第 1 层和第 2 层的神经元数，实验结果如表 2 所示。

表 2 不同 LSTM 神经元数实验结果

Tab.2 Experiment results with different numbers of LSTM neurons

单位：kW

LSTM 神经元数	RMSE	MAE
32，32	3.224	2.680
64，32	2.361	1.642
64，64	2.568	1.878
128，32	3.312	2.832
128，64	2.802	2.033
128，128	2.431	1.914

分析实验结果可知，LSTM 神经元数设置为 64 和 32 时，RMSE 指标值和 MAE 指标值是最小的，神经元数设置为 128 和 128 时，误差相对也较小，但为了防止过拟合现象以及减少计算量，分别设置 LSTM 的神经元数为 64 和 32。同时为减少每次迭代对局部特征的依赖，Dropout 层设置为 0.1，表示在训练过程中会以 10% 的概率丢弃部分隐藏神经元。

3.1.2 实验数据及时间周期

本文所采用的数据为山东省寿光市某百亩大棚园区 2020 年 3 月 1 日—2020 年 6 月 23 日的用电负荷数据，采样点间隔为 1 h，采集了相对应时刻的温度，湿度及降雨量三个气象特征数据。为了验证该算法的预测性能，将数据集分为训练子集和测试子集。为了训练时增强模型的泛化能力，训练子集

和测试子集的比值过小会导致训练不充分，因此本文将 80% 的数据作为训练子集，20% 的数据作为测试子集。

3.1.3　数据处理

本文使用的数据在提取中存在缺失值和异常值，影响预测性能。因此，本文将异常值均视为缺失值，并采用 K 邻近算法对缺失样本值进行估计[22]。

数据预处理采用最大最小值归一化方法，使预处理的数据限定在 0 到 1 中，其原理如式(17)。仿真过程中，在误差评估时再将处理完的数据返回成实际值[23]。

$$X_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{17}$$

其中，X_{norm}为归一化后的数据，$x_{\max}$、$x_{\min}$分别为原始数据集的最大值和最小值。

3.2　实验过程

3.2.1　负荷序列分解分析

VMD 参数 K、τ 和 α 的取值影响分解效果，通过枚举实验，K 由 6 开始，取 8 时中心频率逐渐平稳，当 K 取 9 时中心频率与 $K=8$ 时相似，为避免发生模态混叠，本文选取 $K=8$。为加大对噪声的抑制，τ 的取值为 0。α 的取值过小会导致分解结果出现震荡的情况，如果取值过大会导致分解结果光滑程度过高，因此 α 取样本长度的 2 倍左右[24]，取值为 5 000。如图 4 所示，得到 8 组中心频率各异模态分量。

采用 ACF/PACF 自相关函数法，得到各模态分量与历史值的相关性，确定各自所选取的历史窗口长度。ACF 和 PACF 所选定的 8 组序列模态分量的描绘曲线如图 5 所示。

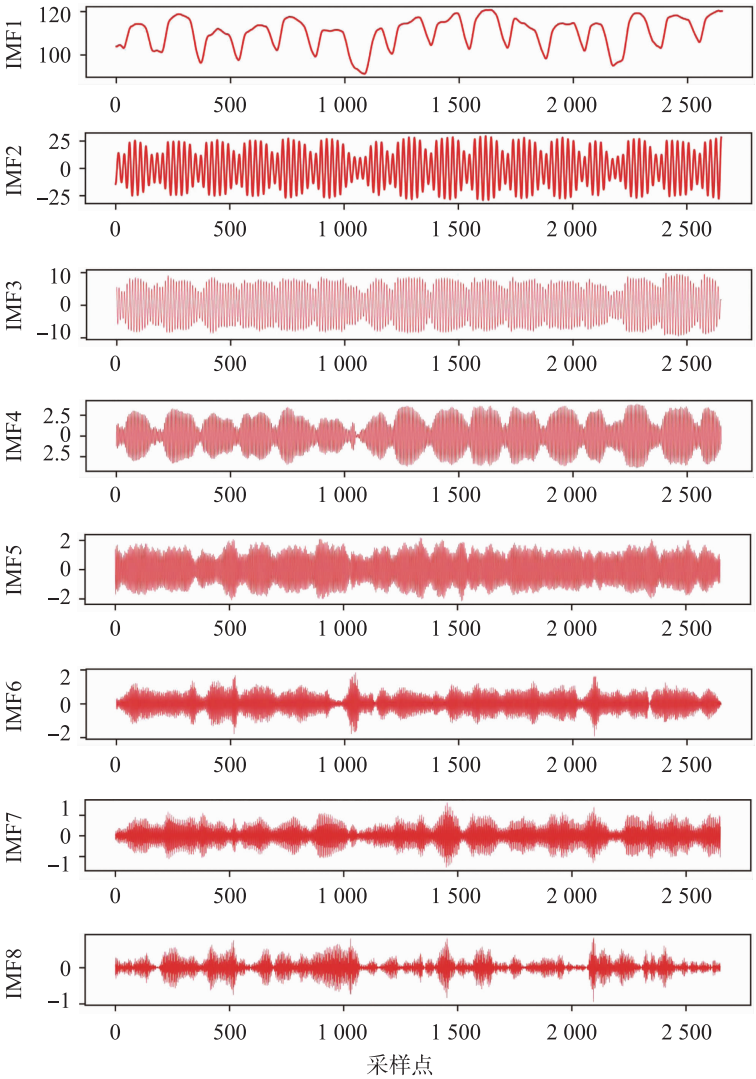

图 4　VMD 分解得到序列分量

Fig.4　Sequence components with VMD decomposition

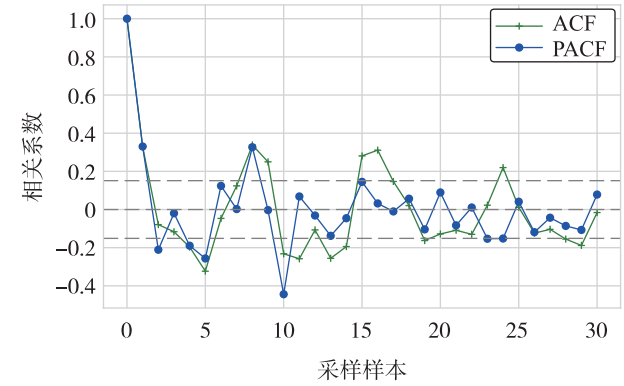

(a) IMF1的ACF、 PACF曲线图

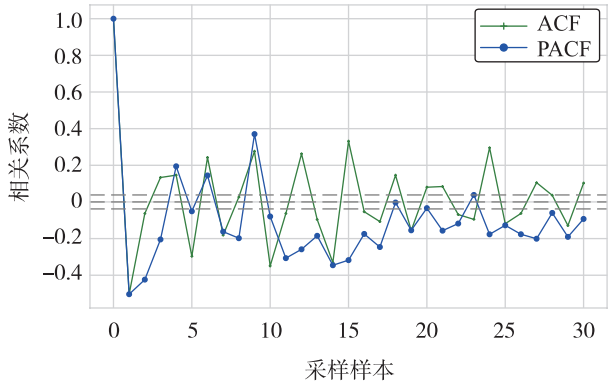

(b) IMF2的ACF、 PACF曲线图

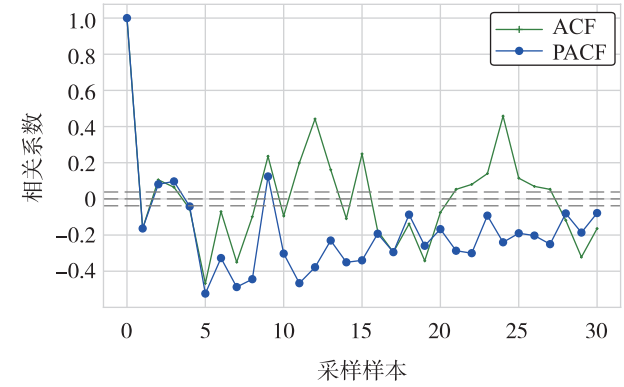

(c) IMF3的ACF、 PACF曲线图

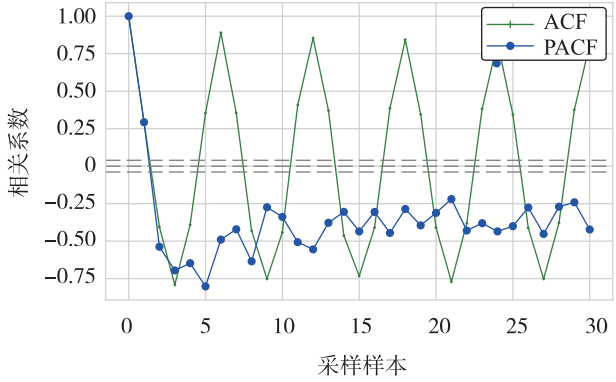

(d) IMF4的ACF、 PACF曲线图

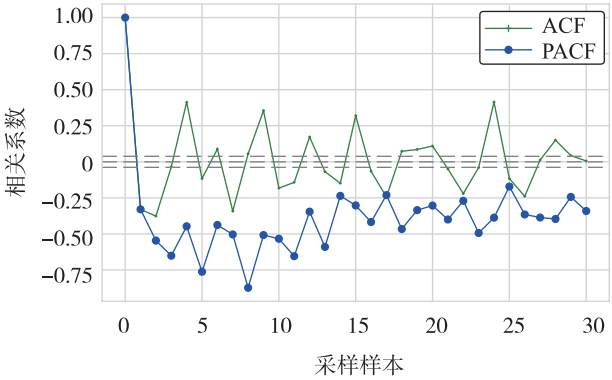

(e) IMF5的ACF、 PACF曲线图

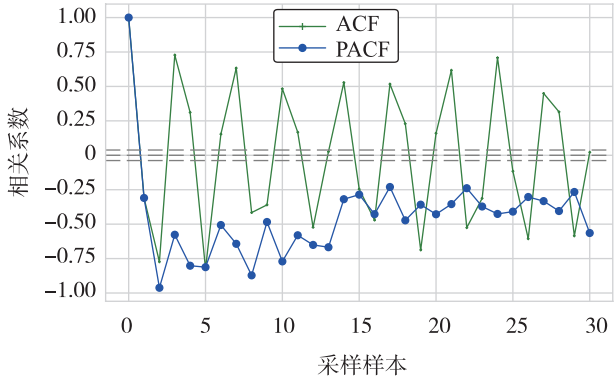

(f) IMF6的ACF、 PACF曲线图

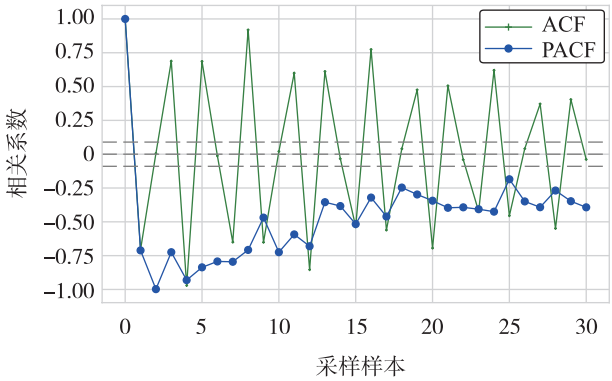

(g) IMF7的ACF、 PACF曲线图

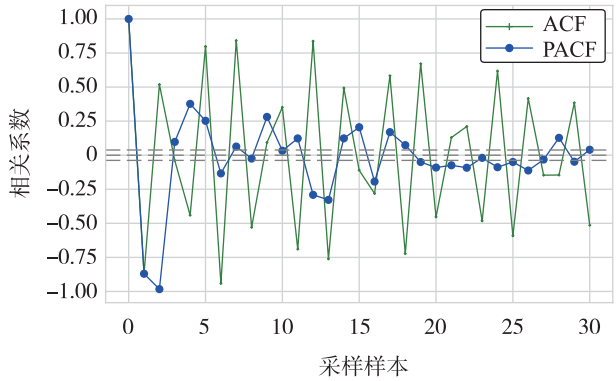

(h) IMF8的ACF、 PACF曲线图

图 5 IMF1 到 IMF8 的 ACF、PACF 曲线图

Fig.5 ACF and PACF curves from IMF1 to IMF8

根据图 5 中的 ACF 和 PACF 曲线图，选择各模态的历史窗口长度，如表 3 所示。

表 3　模态分量时间周期选取

Tab.3　Time period selection of model components

模态分量	历史窗口长度
IMF1	3
IMF2	2
IMF3	4
IMF4	4
IMF5	5
IMF6	5
IMF7	7
IMF8	3

3.2.2　模型验证

选取每组实验数据的 2 122 组数据作为训练集，剩余 530 组数据作为测试集，确定迭代次数并对各分量训练集进行滚动预测，结果如图 6 所示。图中 IMF1 ~ IMF8 的预测结果随着频率变大而变差，但频率越大的模态分量，峰值也更小，因此对最终重构的结果影响较小。

最后得到各分量的误差分析，模态分量的峰值变小，RMSE 和 MAE 也相应的减小，如表 4 所示。

将 8 组模态分量训练的损失函数求平均值，得到模型的损失函数曲线。如图 7 所示，图中蓝线为 8 组损失函数的平均值，在训练初期损失函数快速

表 4　不同模态分量的误差分析

Tab.4　Error analysis of different model components

模态分量	MAPE /%	RMSE /kW	MAE /kW
IMF1	0.35	0.403	0.336
IMF2	0.25	0.622	0.496
IMF3	0.23	0.506	0.329
IMF4	0.17	0.211	0.152
IMF5	0.25	0.059	0.044
IMF6	0.09	0.054	0.042
IMF7	0.11	0.061	0.048
IMF8	0.16	0.038	0.027

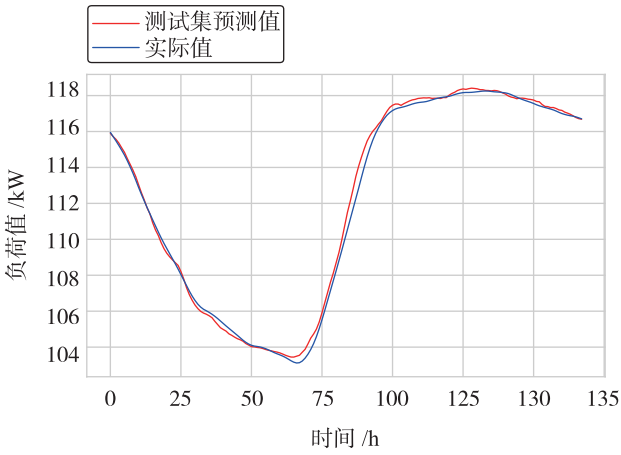

(a) IMF1的预测结果

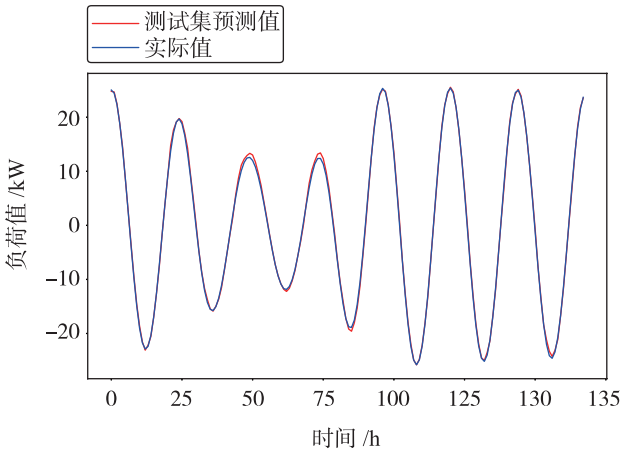

(b) IMF2的预测结果

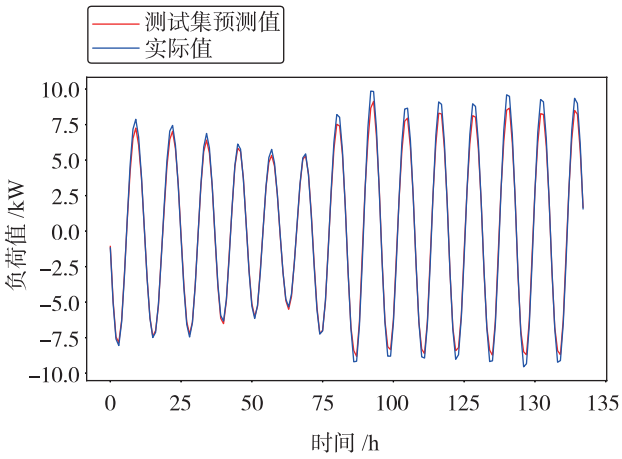

(c) IMF3的预测结果

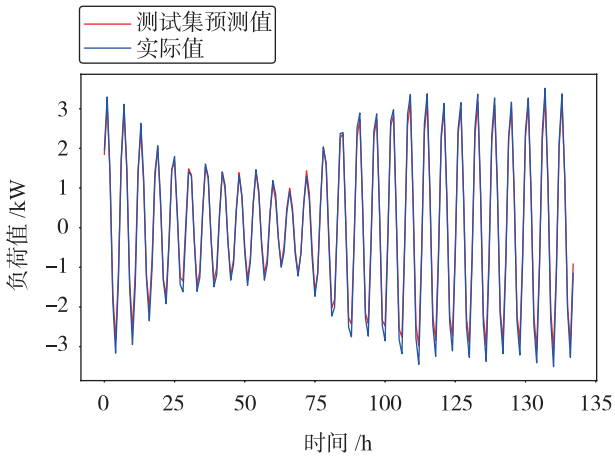

(d) IMF4的预测结果

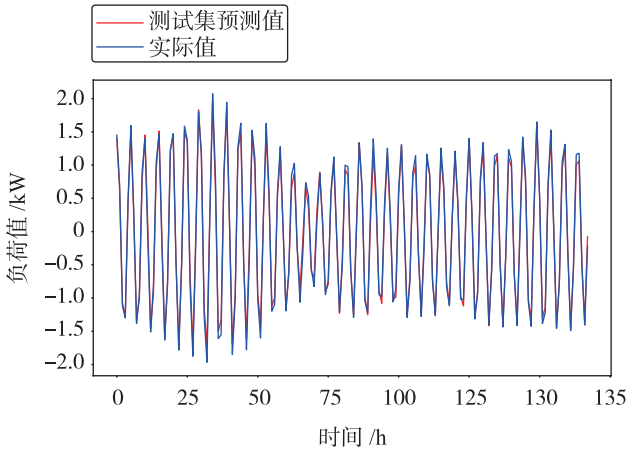

(e) IMF5的预测结果

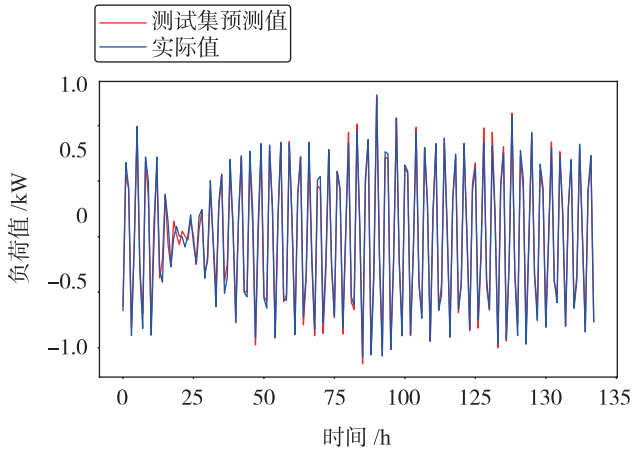

(f) IMF6的预测结果

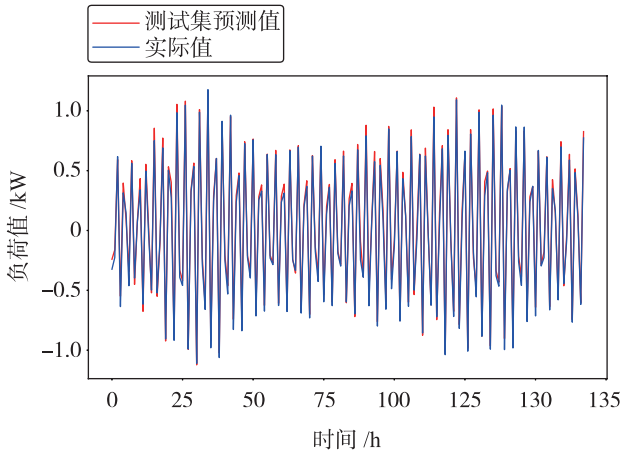

(g) IMF7的预测结果

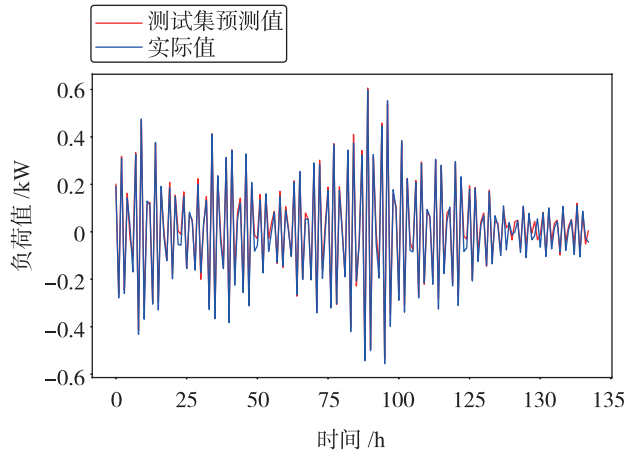

(h) IMF8的预测结果

图 6　IMF1 到 IMF8 的预测结果

Fig.6　Forecast results from IMF1 to IMF8

下降，然后随着训练次数的增加，损失函数下降的速度会逐渐减慢，最终损失函数趋于平稳。趋势表明模型的训练是收敛的，最终达到稳定的状态。

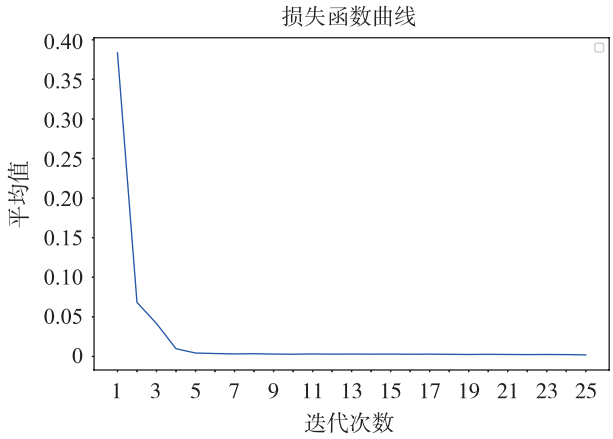

图 7　损失函数曲线

Fig.7　Loss function curve

将 8 组模态分量的预测结果进行重构，得到最终的预测结果与原始负荷数据曲线如图 8 所示，预测的结果能够很好地拟合原始数据，由于分解后中

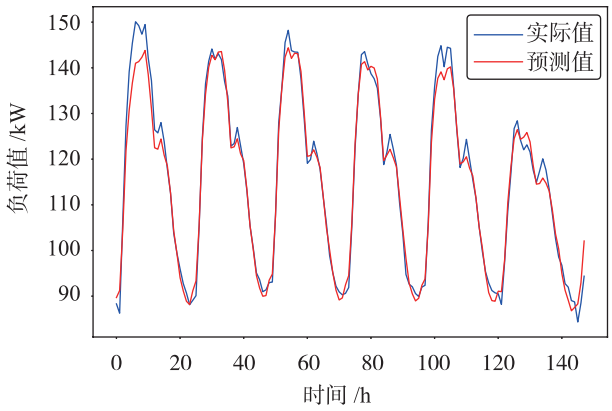

图 8　重构后预测结果与原始负荷曲线图

Fig.8　Comparison between the reconstructed forecast results and original load curve

心频率较高的模态分量波动大，会导致在各个模态分量峰值预测时有误差，但中心频率越高，其上下限越小，因此在重构后峰值的预测还有一定误差。最终预测结果的 RMSE 为 2.361 kW，MAE 为 1.642 kW，MAPE 为 2.101%。

3.2.3　模型对比实验

为了验证本文 VMD-CNN-LSTM 模型的准确性和有效性，开展了该模型和 CNN-LSTM 模型、LSTM 模型以及 VMD-SVR 模型的对比实验。

本文选取了 148 个连续的时间样本点对四种模型的预测曲线进行分析，如图 9 所示。

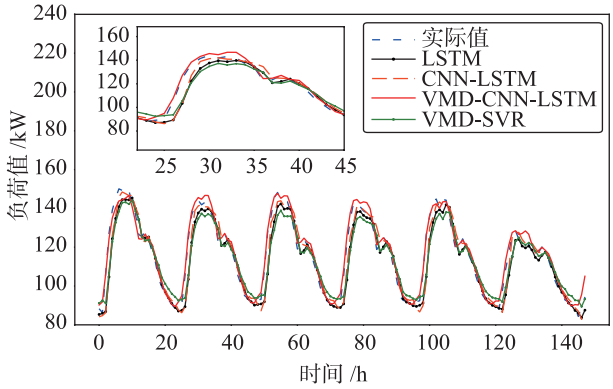

图 9　不同负荷预测模型预测曲线对比

Fig.9　Comparison of forecasting curves among different load forecasting models

由于负荷序列具有非线性，VMD-SVR 模型和 LSTM 模型在每次峰值出现时的预测结果精准性较差，而考虑了气象因素对于负荷的影响，CNN-LSTM 模型与本文提出的 VMD-CNN-LSTM 模型对峰值的预测具有比较精准的结果。对于 VMD-SVR，频率较小的模态分量效果较好，但对于频率较大的模态分量，很难找到一个合适核函数，导致预测结果误差较大，最终无法保证预测结果的精准度。进一步地，选取 22 ~45 的样本区间，如图 9 中放大部分所示，在短时内 VMD-CNN-LSTM 模型对实际数据的拟合度最好，验证了 VMD-CNN-LSTM 对提高时序预测精度的有效性。

图 10 为 4 种模型的误差评价指标对比图，表 5 给出了 4 种模型在测试集上的表现。由结果可知，本文提出的 VMD-CNN-LSTM 模型具有最小的 RMSE、MAPE 和 MAE 误差，应用于短期负荷预测取得了更准确的结果，而 CNN-LSTM 模型次之，单一 LSTM 模型表现较差，VMD-SVR 模型表现最差。在训练时间上，本文提出的 VMD-CNN-LSTM 模型训练时间为 349.41 s，较多于 VMD-SVR 模型的 221.80 s，但是仍优于单一的 LSTM 模型的 661.32 s 和 CNN-LSTM 模型的 461.47 s。单一的 LSTM 模型训练时间最长，因其训练的数据并未经过 VMD 分解和 CNN 的特征提取，计算最为复杂；VMD-SVR 模型由于其计算过程可以直接通过向量运算来实现，因此训练时间最短。

由于本文提出的 VMD-CNN-LSTM 模型采用了 VMD 方法使负荷序列平滑化，降低了负荷波动性对预测的干扰，因此与 CNN-LSTM 模型和单一 LSTM 模型相比，预测精度更高。而 CNN-LSTM 模型的预测效果也优于单一 LSTM 模型，表明了 CNN 方法提取负荷气象特征的有效性。以上 3 种模型与 VMD-SVR 模型对比，预测精度均优于 VMD-SVR 模型，表明 CNN 和 LSTM 对处理负荷序列的非线性、时序性都有相对明显的优势。

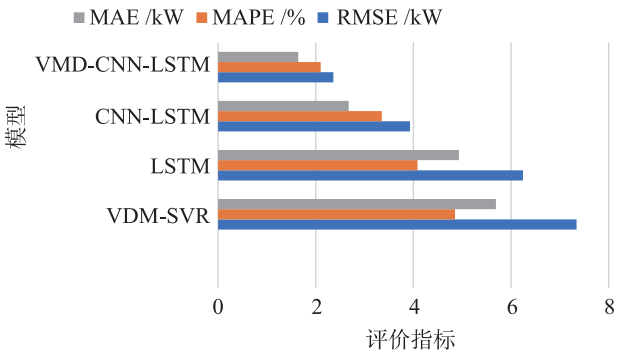

图 10　4 种模型误差评价指标对比图

Fig.10　Comparison of error evaluation indicators among four models

表 5　4 种模型在测试集上的表现

Tab.5　Performance of the four models on the test set

模型	RMSE /kW	MAPE /%	MAE /kW	训练时间 /s
VMD-SVR	7.342	4.852	5.691	221.80
LSTM	6.245	4.085	4.933	661.32
CNN-LSTM	3.932	3.353	2.674	461.47
VMD-CNN-LSTM	2.361	2.101	1.642	349.41

4　结论

本文针对农业大棚负荷受气象因素影响大、波动性大等特点，提出了综合考虑气象特征和时序特征的基于 VMD-CNN-LSTM 的负荷综合预测模型。通过对比分析实验验证，表明本文提出的基于 VMD 方法处理原始负荷序列波动，使序列平滑化，

减少波动性，可有效提高预测模型的处理能力。此外，本文基于 CNN 方法提取负荷序列的气象特征，基于 LSTM 方法提取负荷序列时间特征，可显著提高负荷预测模型的预测精度，可为农业大棚提供准确的负荷数据，保证农业大棚用电的安全性和可靠性。

参考文献

[1] STEPHEN H, SIDDHARTH A, GEORGIOS G, et al. Review of low voltage load forecasting: Methods applications and recommendations[J]. Applied Energy, 2021, 304[2022 - 11 - 13]. https://www.sciencedirect.com/science/article/pii/s0306261921011326. DOI: 10.1016/J.APENERGY.2021.117798.

[2] 安颖坤，朱永丹. 基于线性回归法和指数平滑法对电力负荷的预测[J]. 电力设备管理，2021(5)：177－179.
AN Y K, ZHU Y D. Power load forecasting based on linear regression method and exponential smoothing method[J]. Power Equipment Management, 2021(5): 177－179.

[3] 陈磊，张青云，向晓，等. 改进灰色预测模型在电力负荷预测中的应用[J]. 河北电力技术，2021，40(6)：27－30.
CHEN L, ZHANG Q Y, XIANG X, et al. Application of improved grey forecasting model in power load forecasting[J]. Hebei Electric Power Technology, 2021, 40(6): 27－30.

[4] SONG J C, ZHANG L Y, XUE G X, et al. Predicting hourly heating load in a district heating system based on a hybrid CNN-LSTM model[J]. Energy & Buildings, 2021, 243[2022 - 09 - 10]. https://www.sciencedirect.com/science/article/pii/s0378778821002806. DOI: 10.1016/J.ENBUILD.2021.110998.

[5] Pang C J, Bao T, He L. Power system load forecasting method based on recurrent neural network[C/OL]//E3S Web of Conference on EDP Sciences. Berlin, Germany: Springer, 2020[2022 - 10 - 05]. https://www.researchgate.net/publication/343341555. DOI: 10.1051/e3sconf/202018202007.

[6] HU S Y, ZHAO Y, TIAN X L, et al. Saturated load forecast of Hebei Province based on LSTM[J]. IOP Conference Series: Earth and Environmental Science, 2020, 598(1): 1－10.

[7] LIN J, MA J, ZHU J, et al. Short-term load forecasting based on LSTM networks considering attention mechanism[J/OL]. International Journal of Electrical Power and Energy Systems, 2022, 137[2022－09－18]. https://www.sciencedirect.com/science/article/pii/s0142061521010346. DOI: 10.1016/J.IJEPES.2021.107818.

[8] SAJJAD M, KHAN A Z, ULLAH A, et al. A novel CNN-GRU based hybrid approach for short-term residential load forecasting[J]. IEEE Access, 2020, 99: 143759－143768.

[9] 康义，师刘俊，郭刚. 基于 WT-IPSO-BPNN 的电力系统短期负荷预测[J]. 电气技术，2021，22(01)：23－28，62.
KANG Y, SHI L J, GUO G. Short term load forecasting of power system based on WT-IPSO-BPNN[J]. Electrical Technology, 2021, 22(1): 23－28, 62.

[10] LIU Q Z, SHEN Y B, WU L, et al. A hybrid FCW-EMD and KF-BA-SVM based model for short-term load forecasting[J]. CSEE Journal of Power and Energy Systems, 2018, 4(2): 226－237.

[11] 熊红林，朱人杰，冀和，等. 基于 MI-SVR 模型的航空旅客出行指数预测方法研究[J]. 控制与决策，2021，36(7)：1619－1626.
XIONG H L, ZHU R J, JI H, et al. Research on the prediction method of air passenger travel index based on MI-SVR model[J]. Control and Decision, 2021, 36(7): 1619－1626.

[12] LI J L, SONG Z H, WANG X F, et al. A novel offshore wind farm typhoon wind speed prediction model based on PSO-Bi-LSTM improved by VMD[J/OL]. Energy, 2022, 251[2023 - 01 - 10]. https://www.ntsl.gov.cn/paper-detail.html? id = 47dca45d5cc8beedlaa 2be878259fc7b. DOI: 10.1016/J.ENERGY.2022.123848.

[13] 李文武，石强，李丹，等. 基于 VMD 和 PSO-SVR 的短期电力负荷多阶段优化预测[J]. 中国电力，2022，10(4)：1－9.
LI W W, SHI Q, LI D, et al. Multi stage optimal prediction of short-term power load based on VMD and PSO-SVR[J]. China Power, 2022, 10(4): 1－9.

[14] 高德欣，刘欣，杨清. 基于卷积神经网络与双向长短时融合的锂离子电池剩余使用寿命预测[J]. 信息与控制，2022，51(3)：318－329，360.
GAO D X, LIU X, YANG Q. Residual service life prediction of lithium-ion battery based on convolution neural network and bidirectional short-time fusion[J]. Information and Control, 2022, 51(3): 318－329, 360.

[15] JASEENA K U, KOVOOR B C. A Wavelet-based hybrid multi-step wind speed forecasting model using LSTM and SVR[J]. Wind Engineering, 2021, 45(5): 1123－1144.

[16] FLORENCE J, EMMANUEL B, EMMANUEL M, at el. Robustness of sampled-data homogeneous systems[J/OL]. Automatica, 2021, 123[2023 - 01 - 12]. https:www. sciencedirect. com/science/article/pii/s000510982030546X. DOI: 10. 1016/j. automatica. 2020. 109345.

[17] 韩敏，姜涛，冯守渤. 基于 VMD 循环随机跳跃状态网络的时间序列长期预测[J]. 控制与决策，2020，35(9)：2175 - 2181.
HAN M, JIANG T, FENG S B. Long-term prediction of time series based on VMD cyclic random jump state network[J]. Control and Decision, 2020, 35(9): 2175 - 2181.

[18] QI X J, ZHENG X W, CHEN Q H. A short term load forecasting of integrated energy system based on CNN-LSTM[C/OL]// E3S Web of Conferences on EDP Sciences. Berlin, Germany: Springer, 2020. https://www. resenrchgate. net/publication/344021269. DOI: 10. 1051/e3sconf/202018501032.

[19] 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 X C, CHEN C S, WU J P. Wind farm spatial-temporal combination forecasting model based on CNN-LSTM and deep learning[J]. Information and Control, 2022, 51(4): 498 - 512.

[20] GREFF K, SRIVASTAVA R K, KOUTNíK J, et al. LSTM: A search space odyssey[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 28(10): 2222 - 2232.

[21] 王秋雯，陈彦如，刘媛春. 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[J]. 控制与决策，2021，36(11)：2760 - 2770.
WANG Q W, CHEN Y R, LIU Y C. Short-term passenger flow prediction of urban rail transit based on convolution short-term memory neural network[J]. Control and Decision, 2021, 36(11): 2760 - 2770.

[22] WANG S, WANG X, WANG S, et al. Bi-directional long short-term memory method based on attention mechanism and rolling update for short-term load forecasting[J]. International Journal of Electrical Power and Energy Systems, 2019, 109: 470 - 479.

[23] 庄家懿，杨国华，郑豪丰，等. 基于多模型融合的 CNN-LSTM-XGBoost 短期电力负荷预测方法[J]. 中国电力，2021，54(5)：46 - 55.
ZHUANG J Y, YANG G H, ZHENG H F, et al. CNN-LSTM-XGBoost short-term power load forecasting method based on multi model fusion[J]. China Power, 2021, 54(5): 46 - 55.

[24] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531 - 544.

作者简介

张培霄(1999 -)，男，硕士生。研究领域为电力系统负荷预测。

尹晓红(1985 -)，女，博士，副教授。研究领域为综合能源系统建模与控制。

李少远(1965 -)，男，博士，教授。研究领域为预测控制。