

DOI:10.19651/j.cnki.emt.2416625

基于生成对抗网络和 EMD-ISSA-LSTM 的 短期电力负荷预测*

曾进辉 苏旨音 肖锋 刘颀 孙贤水
(湖南工业大学电气与信息工程学院 株洲 412007)

摘要: 针对电力负荷本身固有的不稳定性及非线性,导致短期电力负荷预测精度难以提升问题。本文提出一种基于 EMD 和 LSTM 相结合的短期电力负荷预测方法。首先,利用 EMD 将原始信号分解为一系列本征模态函数和一个残差量。随后,将所有分量输入 LSTM 中。为进一步提升负荷预测精度和优化模型泛化能力,分别对大分量信号引入改进麻雀搜寻算法优化 LSTM 超参数和对原始负荷数据引入表格生成对抗网络生成新数据样本,形成基于表格生成对抗网络和 EMD-ISSA-LSTM 的短期电力负荷预测方法。最后,分别采用第九届电工数学建模竞赛负荷数据和湖南省某地市含分布式电源的负荷数据进行效果验证。结果表明,在两种数据集下,该模型的平均绝对百分比误差分别为 2.37% 和 2.76%,验证了该方法的有效性。

关键词: 短期电力负荷预测;经验模态分解;长短期记忆神经网络;改进麻雀搜寻算法;生成对抗网络

中图分类号: TM714; TN913 **文献标识码:** A **国家标准学科分类代码:** 470.40

Short-term power load forecasting based on generative adversarial networks and EMD-ISSA-LSTM

Zeng Jinhui Su Zhiyin Xiao Feng Liu Jie Sun Xianshui

(School of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou 412007, China)

Abstract: Aiming at the inherent instability and nonlinearity of power load, which makes it difficult to improve the accuracy of short-term power load prediction. In this paper, we propose a short-term power load prediction method based on the combination of EMD and LSTM. First, the original signal is decomposed into a series of eigenmode functions and a residual quantity using EMD. Subsequently, all the components are input into the LSTM. To further improve the accuracy of load forecasting and optimize the generalization ability of the model, an improved sparrow search algorithm is introduced to optimize LSTM hyperparameters for large component signals, and a table generative adversarial network is introduced to generate new data samples for raw load data, forming a short-term power load forecasting method based on table generative adversarial network and EMD-ISSA-LSTM. Finally, the load data of the ninth mathematical modeling competition for electricians and the load data of a prefecture and city in Hunan Province containing distributed power sources are used to validate the effect, and the results show that the mean absolute percentage error of the model under the two datasets is 2.37% and 2.26%, respectively. The validity of the method is verified.

Keywords: short-term power load forecasting; modal decomposition; long short-term memory neural networks; improved sparrow search algorithm; generative adversarial network

0 引言

准确地短期电力负荷预测对电力系统经济、安全和稳定运行至关重要。近年来,随着清洁能源的不断发展,电网

中分布式电源日趋增加,导致负荷波动性增加,电网出现变压器重过载和主变反送电等诸多问题^[1]。为此,国网相关部门应当制定有序用电计划,合理安排发电、输电及供电,这些计划都高度依赖于准确的电力负荷预测^[2]。因此,提

收稿日期:2024-08-06

* 基金项目:国家自然科学基金(52377185)、湖南省教育厅科学研究项目重点项目(21A0349)、湖南工业大学校级联合项目(CX2404)资助

升电力负荷预测的准确性至关重要。

短期电力负荷是其中一项重要工作,其目的是预测未来一天至数天的电力负荷需求,以确保电力供需平衡^[3]。传统的负荷预测方法有自回归积分滑动平均模型法^[4]、多元线性回归^[5]和灰色预测法^[6]等。这些方法虽然具有较好的解释性,运算速度快,但对大批量数据预测效果差^[7]。随着深度学习的发展和计算机算力的提升,深度学习已经成为主流的负荷预测方法。基于深度学习的负荷预测方法包括卷积神经网络(convolutional neural network, CNN)、循环神经网络(recurrent neural network, RNN)^[8]、长短期记忆神经网络(long short-term memory, LSTM)^[9]和 Transformer^[10]等。其中, LSTM 是由 RNN 发展而来,在 RNN 的基础上加入门控单元和记忆单元,能够消除 RNN 梯度消失和梯度爆炸的风险,在时间序列预测领域有至关重要的作用。然而,对于随机性、波动性较强的负荷序列而言,单一预测方法难以得到理想的预测精度^[9]。因此,各种组合预测方法被应用于短期负荷预测领域,其中模态分解方法与深度学习算法相结合的短期负荷预测方法应用广泛。文献[9]提出一种变分模态分解与 LSTM 相结合的短期电力负荷预测方法。该方法利用变分模态方法将负荷数据分解为高、中、低频信号,以消除负荷数据的波动性,提升负荷预测精度。文献[11]提出一种经验模态分解(empirical mode decomposition, EMD)与 LSTM 相结合的方法。该方法通过 EMD 将负荷数据分解为一系列本征模态函数和残差量,再利用 LSTM 模型得到最终的预测结果。但上述文献均未能考虑 LSTM 本身超参数对负荷预测精度的影响,且手动调参难以得到超参数的最优组合。文献[12]采用 EMD 分解后,分别使用 CNN 和 LSTM 两种算法多次挖掘负荷数据中潜在特征和隐藏信息,以提升负荷预测精度,但其未能考虑负荷预测模型过拟合的现象。

为解决手动调参困难和模型过拟合的现象,研究人员将优化算法与深度学习结合,优化深度学习模型的超参数。文献[13]将 EMD 与 LSTM 算法相结合用于短期电力负荷预测。为解决调参问题,研究人员引入改进粒子群算法优化 LSTM 的超参数,但改进粒子群算法在收敛速度和计算精度等方面与当前其他算法相比效果较差,且该文献未能考虑模型的泛化能力。文献[14]采用麻雀搜寻算法(sparrow search algorithm, SSA)优化 LSTM 的超参数,以提升负荷预测精度,但文献中使用的 SSA 存在容易陷入局部最优和搜索效率不高的问题。

基于上述研究,综合考虑电力负荷本身固有的非线性, EMD 可以将非光滑信号分解为一系列固有模态函数^[15], 本文将 EMD 与 LSTM 结合用于负荷预测,以减少负荷的随机性。此外,本文引入改进麻雀搜寻算法(improved sparrow search algorithm, ISSA)优化 LSTM 的超参数,以及表格生成对抗网络(tabular generative adversarial network, TGAN)用于生成新数据样本,进一步提高模型的

预测精度和泛化能力,从而形成基于 TGAN 和 EMD-ISSA-LSTM 的短期电力负荷预测方法。

1 预测方法理论介绍

1.1 表格生成对抗网络原理

TGAN 是一种通过对抗性训练的思想学习数据中的正常行为。如图 1 所示, TGAN 由生成器和判别器组成,其中 TGAN 生成器网络为 RNN, 判别器为多层感知器。首先,由 TGAN 生成器生成数据样本,并在生成过程中引入噪声。然后,将生成的数据样本与真实负荷数据输入 TGAN 判别器中。当两者数据相似,判别器判定生成的数据为真实样本;否则,判定为假样本。经过多次训练,当生成器生成的数据样本判定为真实数据时,模型训练结束。最终,通过 TGAN 的生成器生成本文所需要的时间序列数据样本。将生成的数据样本插入真实负荷数据集中,在 LSTM 模型训练时,训练集中引入含有噪声的数据样本,能够有效提升模型的泛化能力。

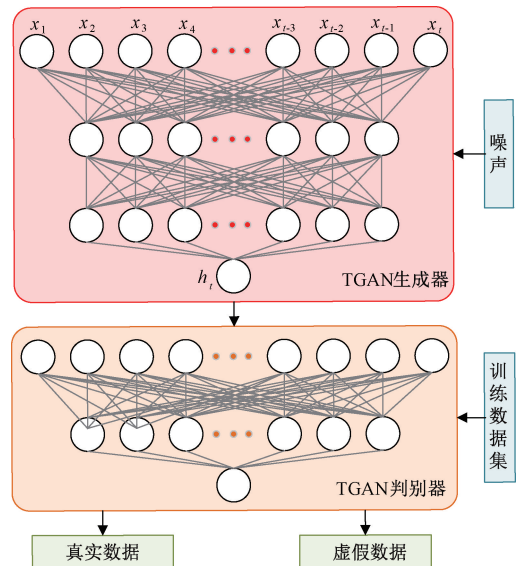


图 1 TGAN 原理

Fig. 1 Principle of TGAN

1.2 经验模态分解原理

将 TGAN 生成的数据样本与原始负荷数据结合输入 EMD 中,分解为几种平滑信号。其中 EMD 主要用于分析非稳定和非线性信号^[15]。将原始信号分解为一系列本征模态函数和一个残差项。计算式如下:

$$A = IMF_1 + IMF_2 + \dots + IMF_m + Residual \quad (1)$$

式中: A 为原始信号; IMF_m 为第 m 个本征模态函数; $Residual$ 为残差项。

如图 2 所示为 EMD 分解得到第一个本征模态函数原理图,其中 S_1 为负荷真实值, S_2 和 S_3 为负荷真实值的极大值和极小值组成的包络线, S_4 为 S_2 和 S_3 的平均值。具体分解步骤如下:

- 1) 对于给定的原始信号, 分别找到极大值和极小值点, 形成极大值和极小值包络线得到 S_2 和 S_3 ;
- 2) 计算极大值和极小值包络线的平均值得到 S_4 ;
- 3) 将原始信号减去 S_4 得到新的信号 S_5 , 如果 S_5 满足本征模态函数的要求, 分解完成。 S_5 就作为第一个本征模态函数。 否则, 将 S_5 继续上述步骤, 直到得到第一个本征模态函数;
- 4) 将原始信号减去第一个本征模态函数, 形成新的信号, 将新的信号作为原始信号进行上述操作。 最后得到一系列本征模态函数和一个残余项, 即得到几种对比于原始信号更平滑的信号。




图 2 EMD 分解原理

Fig. 2 EMD decomposition principle

1.3 LSTM 网络

将 EMD 分解的信号分别输入到不同的 LSTM 模型中, 分别进行预测。 其中 LSTM 模型是由 RNN 发展而来, 一定程度上能避免 RNN 反向传播时的梯度消失和梯度爆炸等问题^[9]。

LSTM 最小单元如图 3 所示, 其中 σ 为 sigmoid 函数, C_t 为本细胞输出的记忆信息, h_t 为本细胞的输出, C_{t-1} 为上一个细胞输出的记忆信息, h_{t-1} 为上一个细胞的输出, x_t 表示该细胞的输入数据, \tanh 是一种激活函数。 每个 LSTM 单元的输出与下一层神经网络链接, 最终得到模型的输出。

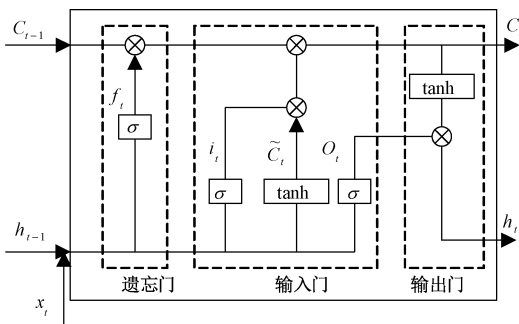


图 3 LSTM 最小单元

Fig. 3 LSTM minimum cell

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \quad (2)$$

$$\tanh(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (3)$$

LSTM 最小单元的工作原理可以描述为:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (5)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (7)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (8)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (9)$$

式中: W_f 和 b_f 分别为权重矩阵和偏置矩阵。

1.4 改进麻雀搜寻算法

ISSA 是一种模仿麻雀觅食的群体智能优化算法。 文中采用 ISSA 优化 LSTM 的超参数^[14]。 麻雀搜寻算法的具体原理如下。

矩阵 X 表示麻雀种群, 如式(10)所示。

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1d} \\ x_{21} & x_{22} & \cdots & x_{2d} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nd} \end{bmatrix} \quad (10)$$

式中: n 表示麻雀种群数; d 表示需要优化的 LSTM 超参数的个数; x 表示麻雀种群中每个麻雀。

根据每一组 LSTM 的超参数可以得到 n 个适应度函数, 如式(11)所示。

$$F_x = \begin{bmatrix} f(x_{11}, x_{12}, \cdots, x_{1d}) \\ f(x_{21}, x_{22}, \cdots, x_{2d}) \\ \vdots \\ f(x_{n1}, x_{n2}, \cdots, x_{nd}) \end{bmatrix} \quad (11)$$

在这组适应度函数中, 有一组最佳适应度函数取最小值的 LSTM 的超参数, 可以描述为如式(12)所示。

$$best_1 = [x_{n1}, x_{n2}, \cdots, x_{nd}] \quad (12)$$

之后将麻雀种群分为两种, 距离最佳适应度函数较近的麻雀称为发现者, 而最佳适应度函数较远的麻雀称为跟随者, 并随机分配边界者来避免危险。 在获得最佳适应度函数后, 将会更改发现者和跟随者的位置, 其中发现者位置更新如式(13)所示。

$$x_{i,j}^{t+1} = \begin{cases} x_{i,j}^t \cdot \exp\left(\frac{-1}{\alpha \cdot i_{termax}}\right), & R_2 < ST \\ x_{i,j}^t + Q, & R_2 \geq ST \end{cases} \quad (13)$$

式中: i_{termax} 表示麻雀寻优算法中设定的最大迭代次数; α 表示 $[0, 1]$ 的均匀随机数; Q 表示标准正态随机数; R_2 表示捕食者是 $[0, 1]$ 的随机数; ST 表示发现者发现捕食者的预警值; $x_{i,j}^{t+1}$ 表示更新后的位置; $x_{i,j}^t$ 表示更新前的位置。

追随者位置更新如式(14)所示。

$$x_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{x_{worst}^t - x_{i,j}^t}{i^2}\right), & i > \frac{n}{2} \\ x_{best}^t - \frac{1}{d} \sum_{j=1}^d |x_{i,j}^t - x_{best}^t| \cdot rand(-1,1), & \text{其他} \end{cases} \quad (14)$$

式中: x_{worst}^t 表示当前种群中适应度最差的麻雀; x_{best}^t 表示当前种群中适应度最好的麻雀个体。

警戒者位置更新如式(15)所示。

$$x_{i,j}^{t+1} = \begin{cases} x_{best}^t + \beta \cdot |x_{i,j}^t - x_{best}^t|, & f_i > f_g \\ x_{i,j}^t + K \cdot \left(\frac{|x_{i,j}^t - x_{worst}^t|}{(f_i - f_w) + \varepsilon}\right), & f_i = f_g \end{cases} \quad (15)$$

式中: β 表示标准正态分布数; K 的取值范围是 $-1 \sim 1$; f_g 和 f_w 分别表示麻雀的最佳和最差适应度值; f_i 表示麻雀当前的适应度值。

麻雀搜寻算法的总体是通过随机初始化获取的, 每一个麻雀个体的质量较低, 会影响算法的收敛速度。因此, 在此基础上改变种群初始化, 如式(16)所示。

$$X_i^* = rand \cdot (lb + ub) - X_i \quad (16)$$

式中: $rand$ 是一个 $0 \sim 1$ 的随机数; lb 与 ub 分别表示搜索空间的上界和下界。

同时麻雀搜寻算法中警戒者位置更新, K 在平衡全局搜索能力和跳出局部最优有很大的作用。 K 表示一个从 $-1 \sim 1$ 的随机数, 这种参数设置会导致麻雀搜寻算法在查询最优值时得不到充分的搜寻, 可能会陷入局部最优的现象。因此, 对 K 进行改进, 如式(17)所示。

$$K = (f_g - f_w) \cdot (2 \cdot rand - 1)^{1.5} \quad (17)$$

最终, 通过不断迭代更新麻雀种群的位置找到最佳适应度的麻雀个体, 即有最佳适应度值的一组 LSTM 的超参数。

2 负荷预测模型

2.1 短期电力负荷预测框架

模型框架如图 4 所示, 首先通过 TGAN 生成负荷数据, 将其与真实负荷数据结合得到原始信号。随后, 通过 EMD 将原始信号分解为一系列本征模态函数和一个残差量。本方法中将小于原始信号一个数量级的信号规定为小分量信号, 其他的为大分量信号。由于大分量信号相比于小分量信号对负荷预测精度影响更大, 应用 EMD 将不稳定性信号从大分量信号中去除使其信号更加平滑, 有利于对大分量信号预测。经过调试, 负荷信号被分解为五个信号, 其中信号 1 到信号 4 为小分量信号, 信号 5 为大分量信号。为了在不影响模型训练速度的情况下提升模型精度, 将小分量信号分别输入 LSTM 中进行预测, 小信号分量的 LSTM 使用同一个 LSTM 模型, 模型参数通过调试得到。大分量信号则输入 ISSA-LSTM 中训练, 大分量信号的 LSTM 模型部分超参数通过 ISSA 优化; 最后, 预测得到的五种信号反归一化后再相加得到最终的预测结果。

2.2 模型的输入输出

图 5 所示为模型的输入数据形状, 其中横轴为时间轴

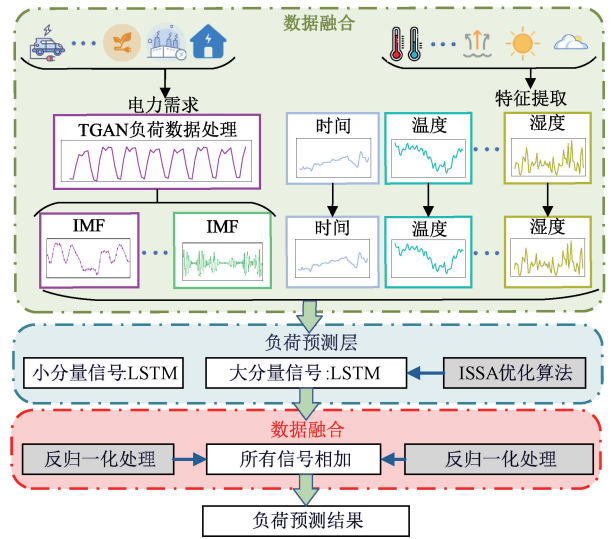


图 4 预测框架

Fig. 4 Forecasting framework

T , 纵轴为每次输入的特征数 F , 竖轴为输入的数据长度 S 。将时间看作一个维度, 模型的输入数据为三维数据, 某一时间点模型的输入数据为二维数据, 该二维数据中的一个维度为特征数 F , 由历史负荷数据和其他特征数据构成。其他特征数据包括温度、降雨量、日期和星期数据等; 另一个维度为输入数据长度 S , 即一天的负荷量。每次输入模型的数据量是 $S \times F$, 即一个 S 行 F 列的矩阵。




图 5 模型输入数据形状

Fig. 5 Shape of model input data

图 6 为大分量信号的 LSTM 模型框架和数据流向, 以输入特征数为 6, 输入时间序列长度为 96, 第 1 层神经元的个数为 104, 第 2 层神经元的个数为 134 为例分析。由于 LSTM 模型的输入必须是三维数据, 因此在某一时刻将二维数据扩展称为三维数据。首先, 将三维数据输入 LSTM 的输入层, 经过输入层后数据结构不变; 其次, 将输入层的输出输入至 LSTM 的第 1 层网络中, 由于第一层神经元的个数是 104 个, 因此该层输出数据的结构由原先的 96×6 变为 96×104 ; 再次, 将第 1 层 LSTM 的输出输入到第 2 层

LSTM 中,由于第 2 层的神经元的个数为 134,因此该层输出数据的结构由原先的 96×104 变为 96×134 ;最终,将第 2 层 LSTM 的输出通过全连接层得到 96×1 的预测结果,即 96 个负荷值。小信号的 LSTM 模型预测框架与数据流向与之相同,模型参数通过调参获得。

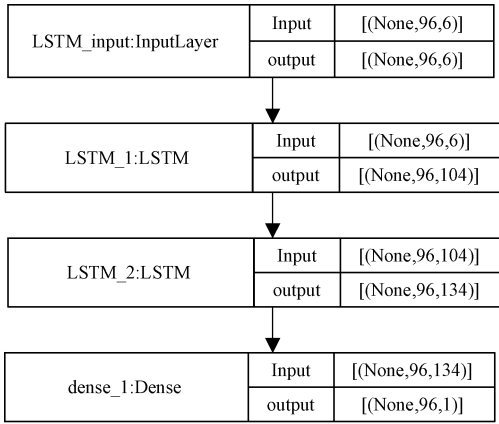


图 6 LSTM 模型框架

Fig. 6 LSTM modeling framework

3 案例分析

为验证基于 TGAN 和 EMD-ISSA-LSTM 方法的有效性,本文分别采用第九届电工数学建模大赛 A 题的负荷数据和湖南省某地市含分布式电源的负荷数据进行实验下文分别称为案例 1 和案例 2。该实验使用 Pycharm 编译器,并在 Anaconda 环境中的 2.6.0 版 Tensorflow-gpu 深度学习框架和 RTX3070Ti 显卡下实现。

3.1 案例 1 特征选择

案例 1 使用 2012~2014 三年的负荷数据,每 15 min 一个数据点,即每天 96 个数据点,共 210 432 条负荷数据,数据链接如下: <https://zhuanlan.zhihu.com/p/150954853>。由于数据量大,训练集与测试集数据采用 9 : 1 比例划分。特征数据与负荷数据按时间关系对应,为避免特征数据冗余,采用皮尔逊相关系数法^[16]进行相关性分析。

图 7 所示为输入特征的相关性分析,其中皮尔逊系数绝对值越大,两变量之间的相关性越高,负值表示两个变量之间呈现负相关。从热力图中可以看出,负荷数据与温度特征之间的相关性最高,降雨量数据与负荷数据的相关系数为 0.069,相关性较低,因此,将降雨量数据从输入特征中去除。

在进行实验对比时,文中使用 4 种模型评价指标,分别是决定系数 (R^2)、平均绝对误差 mean absolute error, MAE)、均方根误差 (root mean square error, RMSE)、平均绝对百分比误差 (mean absolute percentage error, MAPE)^[17-18]。

不同特征下单一 LSTM 模型的评价指标如表 1 所示,其中特征项为在基本特征基础上添加的特征。




图 7 案例 1 相关性分析热力图

Fig. 7 Heat map of correlation analysis for case 1

表 1 案例 1 添加不同特征下的模型评价指标

Table 1 Model evaluation metrics with different features added for case 1

特征	R^2	MAE	RMSE	MAPE/%
降雨量	0.95	0.024	0.031	6.53
星期特征	0.96	0.023	0.029	6.09
季节特征	0.94	0.030	0.036	6.58
全部特征	0.96	0.024	0.030	6.12

从表 1 中可以看出,在基本特征中加入星期特征的决定系数为 0.96,平均绝对误差为 0.023,均方根误差为 0.029,平均绝对百分比误差为 6.09%。有最大的决定系数和最小的误差。最终,选择负荷、温度、日期和星期作为模型的输入特征。

3.2 案例 1 预测结果对比分析

首先,本文使用 TGAN 生成时序负荷数据,每隔 30 天生成一天的时序数据代替原始负荷数据,以提升模型的泛化能力。图 8 为真实数据与生成数据的结果对比图,其中 TGAN 生成的时间序列数据中加入噪声。该网络模型的各个参数设置如下:最大迭代次数为 32,训练时模型的批次大小为 200,生成噪声的输入维度为 200,噪声上限为 0.2,学习率为 0.001。

其次分析 ISSA 优化 LSTM 参数结果,通过调参得到 LSTM 的最佳网络层为两层。设置 ISSA 的适应度函数为 RMSE,ISSA 的迭代次数为 100。当 LSTM 的优化参数为两层的神经元数量时,通过 ISSA,得到第一层和第二层神经元分别为 104 和 134 时 RMSE 最小。

本实验对比传统的自回归差分移动平均模型 (autoregressive integrated moving average model, ARIMA)^[4]、当前主流的负荷预测模型 LSTM^[19] 和时间卷积神经网络 (temporal convolutional neural, TCN)^[20],同时




图 8 案例 1 中 TGAN 生成数据样本

Fig. 8 Sample of TGAN-generated data in case 1

为进一步对比 EMD 对于负荷预测的影响加入 ISSA-LSTM 模型,并且与 CNN-BiLSTM^[21]模型、EMD-IPSO-LSTM^[13]进行对比。

小分量信号 LSTM 模型参数为一层 LSTM 隐藏层,神经元的个数为 50,批处理大小为 256。

大分量信号 LSTM 模型参数为两层 LSTM 隐藏层,ISSA 的迭代次数为 100,经 ISSA 优化得到两层神经元的数量分别为 104 和 134,批处理大小为 256。

图 9 为原始负荷波形,图 10 为经过 EMD 分解后的波形。其中 IMF_1 到 IMF_4 为分解出的本征模态函数, IMF_5 为残差量。




图 9 案例 1 原始负荷波形

Fig. 9 Original load waveform in case 1

如图 11 所示,为最终预测结果,将负荷不稳定处放大,可以看出本文所提方法曲线最接近真实负荷曲线。

根据预测结果,计算 4 种模型评价指标如表 2 所示,本文方法的决定系数为 0.982,平均绝对误差为 0.012,均方根误差为 0.016,平均绝对百分比误差为 2.37%。该方法具有最大的 R^2 和最小的误差。相对于其他负荷预测模型能够有效提升负荷预测精度。

不同季节下的本模型评价指标如表 3 所示,通过不同场景下模型评价指标验证了该方法的泛化能力。

在本方法中,训练模型时使用 ISSA 对 LSTM 模型的超参数迭代。当模型训练完成,参数确定后。在进行负荷预测时,先经过 EMD 算法分解后,再调用训练好的 LSTM




图 10 案例 1 EMD 分解后的波形

Fig. 10 Waveforms after EMD decomposition in case 1




图 11 案例 1 预测结果对比

Fig. 11 Comparison of prediction results in case 1

表 2 案例 1 模型评价指标

Table 2 model evaluation indicators in case 1

模型	R^2	MAE	RMSE	MAPE/%
ARIMA ^[4]	0.649	0.046	0.055	9.46
LSTM ^[19]	0.923	0.030	0.036	5.91
TCN ^[20]	0.944	0.023	0.029	4.27
ISSA-LSTM	0.951	0.022	0.029	4.13
CNN-BiLSTM ^[21]	0.978	0.017	0.020	3.28
EMD-IPSO-LSTM ^[13]	0.977	0.015	0.019	2.86
本方法	0.982	0.012	0.016	2.37

模型进行负荷预测得到最终结果。与传统的 LSTM 模型相比效率方面增加了 EMD 分解和 4 次调用 LSTM 模型预

测的时间。经过仿真验证单次负荷预测时间为 91.341,83 秒,能够满足当前电力负荷预测效率需求。

表 3 案例 1 不同季节下本方法模型评价指标

Table 3 Evaluation indicators of this methodology model under different seasons in case 1

季节	R ²	MAE	RMSE	MAPE/%
春	0.981	0.012	0.017	2.46
夏	0.979	0.013	0.020	2.75
秋	0.983	0.012	0.016	2.32
冬	0.982	0.012	0.016	2.37

3.3 案例 2 特征选择

案例 2 使用 2020 年 1 月 1 日~2022 年 12 月 31 日,每 15 min 一个数据点,即每天 96 个数据点,共 210 432 条负荷数据,其中分布式光伏发电渗透率 27%。气象特征数据来自公开气象网站:http://www.meteomanz.com/。气象特征包含平均温度、最高温度、最低温度、相对湿度、压强、风向、风速、降雨量 8 种特征数据。在气象特征的基础上引入了星期特征。训练集与测试集数据采用 9 : 1 比例划分。

使用皮尔逊相关系数进行相关性分析,图 12 为相关性分析热力图。从图中可以得出风速与负荷数据的相关系数为 0.03,相关性较低。最终,选择负荷、温度、压强、风向、降雨量和星期特征作为模型的输入特征。

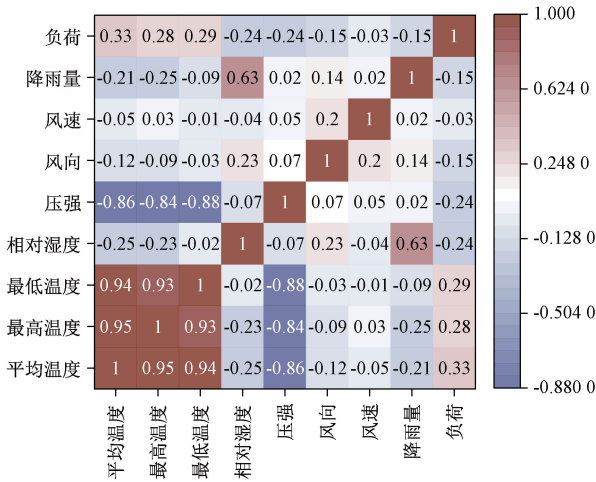


图 12 案例 2 负荷与气象特征之间相关性热力图

Fig. 12 Heat map of correlation between load and meteorological characteristics in case 2

3.4 案例 2 预测结果对比分析

首先,本文使用 TGAN 生成时序负荷数据,每隔 30 天生成一天的时序数据代替原始负荷数据,以提升模型的泛化能力。

其次分析 ISSA 优化 LSTM 参数结果,通过调参确定 LSTM 的最佳网络层为两层。设置 ISSA 的适应度函数为 RMSE,ISSA 的迭代次数为 100。当 LSTM 的优化参数为

两层的神经元数量时,通过 ISSA 得到第 1 层神经元为 152,第 2 层神经元为 150, RMSE 有最小值。

采用与案例 1 相同的预测方法进行对比实验。如图 13 所示,为最终预测结果,将负荷不稳定处放大,可以看出本文所提方法曲线最接近真实负荷曲线。




图 13 案例 2 预测结果对比

Fig. 13 Comparison of predicted results in case 2

同时,根据预测结果,计算 4 种模型评价指标如表 4 所示,加粗部分为本文方法,其决定系数为 0.978,平均绝对误差为 0.013,均方根误差为 0.017,平均绝对百分比误差为 2.76%。该方法有最大的 R² 和最小的误差,相对于其他负荷预测模型能够有效提升负荷预测精度。

表 4 案例 2 模型评价指标

Table 4 Indicators for model evaluation in case 2

模型	R ²	MAE	RMSE	MAPE/%
ARIMA ^[4]	0.706	0.037	0.043	8.02
LSTM ^[19]	0.952	0.020	0.025	4.00
TCN ^[20]	0.855	0.028	0.034	5.88
ISSA-LSTM	0.962	0.017	0.021	3.56
CNN-BiLSTM ^[21]	0.964	0.016	0.022	3.31
EMD-IPSO-LSTM ^[13]	0.965	0.016	0.021	3.33
本文	0.978	0.013	0.017	2.76

不同季节下的本模型评价指标如表 5 所示,通过不同场景下的模型评价指标验证该模型的泛化能力。

表 5 案例 2 不同季节下本方法模型评价指标

Table 5 Evaluation indicators of this methodology model under different seasons in case 2

季节	R ²	MAE	RMSE	MAPE/%
春	0.976	0.013	0.017	2.79
夏	0.975	0.013	0.018	2.83
秋	0.978	0.013	0.017	2.66
冬	0.978	0.013	0.017	2.76

4 结 论

为有效提升短期电力负荷预测精度,本文针对负荷数据的不稳定性和非线性,提出一种基于 TGAN 和 EMD-ISSA-LSTM 相结合的短期电力负荷预测方法。选取第九届电工数学建模大赛 A 题负荷数据集和湖南省某地市含分布式能源负荷数据集进行仿真验证。该模型在预测精度方面,相较于 ARIMA、LSTM、TCN 和 EMD-IPSO-LSTM 等方法,能够有效提升负荷预测精度。在模型泛化能力方面,通过不同地区、不同场景进行案例验证,表明该模型有一定的泛化能力。在预测效率方面,相较于单一 LSTM 模型,增加了 EMD 分解和四次调用 LSTM 模型的时间,一次预测时间为 90 s 左右,能够满足当前负荷预测的效率需求。将本方法应用于电力系统运行决策,能够有效提升电网调度水平。此外,本方法具有一定的通用性,也可用于其他领域。

参考文献

- [1] 孟金鑫, 黄山, 印月. 基于特征优选策略和 DLSTMs-FCN 优化的短期负荷预测[J]. 电子测量技术, 2023, 46(10): 46-52.
MENG J X, HUANG SH, YIN Y. Short-term load forecasting model based on feature optimization strategy and DLSTMs-FCN [J]. Electronic Measurement Technology, 2023, 46(10): 46-52.
- [2] 杨邓, 杨俊杰, 胡晨阳, 等. 基于改进 LSSVM 的短期电力负荷预测[J]. 电子测量技术, 2021, 44(18): 47-53.
YANG D, YANG J J, HU CH Y, et al. Short-term power load forecasting based on improved LSSVM[J]. Electronic Measurement Technology, 2021, 44(18): 47-53.
- [3] 朱继忠, 董瀚江, 李盛林, 等. 数据驱动的综合能源系统负荷预测综述[J]. 中国电机工程学报, 2021, 41(23): 7905-7923.
ZHU J ZH, DONG H J, LI SH L, et al. Review of data-driven load forecasting for integrated energy system[J]. Proceedings of the CSEE, 2021, 41(23): 7905-7923.
- [4] 李丹, 孙光帆, 缪书唯, 等. 基于多维时序信息融合的短期电力负荷预测方法[J]. 中国电机工程学报, 2023, 43(S1): 94-106.
LI D, SUN G F, LIAO SH W, et al. A short-term power load forecasting method based on multidimensional temporal information fusion [J]. Proceedings of the CSEE, 2023, 43(S1): 94-106.
- [5] 张波, 赵永红, 唐亮, 等. 基于 AMI 数据的城市低压配电网拓扑校验方法研究[J]. 电子测量技术, 2019, 42(6): 67-71.
ZHANG B, ZHAO Y H, TANG L, et al. Research on topology verification of city LV power distribution network based on AMI[J]. Electronic Measurement Technology, 2019, 42(6): 67-71.
- [6] 陈鹏宇, 秦岭. 变形监测灰色预测模型的对比及替代方法研究[J]. 大地测量与地球动力学, 2024, 44(4): 382-390.
CHEN P Y, QIN L. GNSS coordinate time series denoising method combining SSA-VMD and wavelet decomposition [J]. Journal of Geodesy and Geodynamics, 2024, 44(4): 382-390.
- [7] 穆晨宇, 薛文斌, 穆羨琰, 等. 基于 VMD-LSTM-Attention 模型的短期负荷预测研究[J]. 现代电子技术, 2023, 46(17): 174-178.
MU CH Y, XUE W B, MU X Y, et al. Research on short-term load forecasting based on VMD-LSTM-Attention model[J]. Modern Electronics Technique, 2023, 46(17): 174-178.
- [8] 郎巨林, 郑晟. 基于 CNN-RNN 集成的隧道事故异常声音识别 [J]. 电子测量技术, 2023, 46(20): 164-169.
LANG J L, ZHENG SH. Tunnel accident abnormal sound recognition based on CNN-RNN integration[J]. Electronic Measurement Technology, 2023, 46(20): 164-169.
- [9] 阳曾, 丁施尹, 叶萌, 等. 基于变分模态分解和深度学习的短期电力负荷预测模型[J]. 电测与仪表, 2023, 60(2): 126-131, 146.
YANG Z, DING SH Y, YE M, et al. Short-term load forecasting model based on VMD and LSTM [J]. Electronic Measurement and Instrumentation, 2023, 60(2): 126-131, 146.
- [10] 田俊豪, 刘立程, 王小林, 等. 基于 Transformer 模型的连续无创血压预测方法[J]. 电子测量技术, 2024, 47(3): 102-108.
TIAN J H, LIU L CH, WANG X L, et al. Continuous non-invasive blood pressure prediction method based on Transformer [J]. Electronic Measurement Technology, 2024, 47(3): 102-108.
- [11] 魏骛, 茅大钧, 韩万里, 等. 基于 EMD 和长短期记忆网络的短期电力负荷预测研究[J]. 热能动力工程, 2020, 35(4): 203-209.
WEI AO, MAO D J, HAN W L, et al. Short-term load forecasting based on EMD and long short-term memory neural networks[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(4): 203-209.

- [12] 徐岩, 向益锋, 马天祥. 基于 EMD-CNN-LSTM 混合模型的短期电力负荷预测[J]. 华北电力大学学报, 2022, 49(2): 81-89.
XU Y, XIANG Y F, MA T X, et al. Short-term power load forecasting method based on EMD-CNN-LSTM hybrid model [J]. Journal of North China Electric Power University, 2022, 49(2): 81-89.
- [13] 赵一鸣, 吉月辉, 刘俊杰, 等. 基于 EMD-IPSO-LSTM 模型的短期电力负荷预测[J]. 国外电子测量技术, 2023, 42(1): 132-137.
ZHAO Y M, JI Y H, LIU J J, et al. Short term power load forecasting based on EMD-IPSO-LSTM mode [J]. Foreign Electronic Measurement Technology, 2023, 42(1): 132-137.
- [14] 赵婧宇, 池越, 周亚同. 基于 SSA-LSTM 模型的短期电力负荷预测[J]. 电工电能新技术, 2022, 41(6): 71-79.
ZHAO J Y, CHI Y, ZHOU Y T. Short-term load forecasting based on SSA-LSTM model[J]. Advanced Technology of Electrical Engineering and Energy, 2022, 41(6): 71-79.
- [15] 唐塬, 常俊杰, 彭少雄, 等. 基于 EMD 与神经网络的超声栓子信号分类研究[J]. 中国测试, 2023, 49(8): 15-20.
TANG Y, CHANG J J, PENG SH X, et al. Research on ultrasonic emboli signal classification based on EMD and neural network[J]. China Measurement and Test, 2023, 49(8): 15-20.
- [16] 方娜, 肖威, 邓心. 基于 PCC-ISSA-BP 燃料电池剩余寿命预测[J]. 电子测量技术, 2023, 46(24): 77-83.
FANG N, XIAO W, DENG X. Residual life prediction of fuel cell based on PCC-ISSA-BP [J]. Electronic Measurement Technology, 2023, 46(24): 77-83.
- [17] DONG J ZH, LUO L, LU Y, et al. A parallel short-term power load forecasting method considering high-level elastic loads [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-10.
- [18] WU Y J, CONG P ZH, WANG Y L. Charging load forecasting of electric vehicles based on VMD-SSA-SVR [J]. IEEE Transactions on Transportation Electrification, 2024, 2(10): 3349-3362.
- [19] 崔星, 李晋国, 张照贝, 等. 基于改进粒子群算法优化 LSTM 的短期电力负荷预测[J]. 电测与仪表, 2024, 61(1): 131-136.
CUI X, LI J G, ZHANG ZH B, et al. The short-term power load forecasting based on NIWPSO-LSTM neural network [J]. Electronic Measurement Technology, 2024, 61(1): 131-136.
- [20] BAI SH J, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. ArXiv preprint arXiv: 1803.01271, 2018.
- [21] 杨桂松, 高炳涛, 何杏宇. 融合 CNN 与 BiLSTM 模型的短期电能负荷预测[J]. 小型微型计算机系统, 2024, 45(9): 2253-2260.
YANG J S, GAO B T, HE X Y. Short-term power load forecasting based on CNN and BiLSTM model [J]. Journal of Chinese Systems, 2024, 45(9): 2253-2260.

作者简介

曾进辉, 教授, 博士生导师, 主要研究方向为负荷预测、直流配电网、能量路由器等。

E-mail: zjh@hut.edu.cn

刘颖(通信作者), 博士, 硕士生导师, 主要研究方向为负荷预测、多能互补调度等。

E-mail: 14393@hut.edu.cn