

基于 SSA-LSTM 模型的短期电力负荷预测

赵婧宇, 池 越, 周亚同

(河北工业大学电子信息工程学院, 天津 300401)

摘要: 电力负荷预测实质是时间序列预测问题, 存在非平稳性和影响因素的复杂性。为了提高预测精度, 解决长短期记忆神经网络 (LSTM) 参数选取随机性大、选取困难的问题, 本文提出了一种利用麻雀搜索算法 (SSA) 优化长短期记忆神经网络参数的短期电力负荷预测模型 (SSA-LSTM), 通过历史用电负荷数据、相关影响因素数据对待预测日进行负荷预测。首先, 对历史用电负荷数据、天气、节假日等影响因素进行预处理。其次, 将处理好的数据用以训练模型, 借助麻雀搜索算法对长短期记忆神经网络的参数进行寻优, 使输入数据与网络结构更好地进行匹配。最后, 进行负荷预测同时对比其他算法模型进行分析。算例结果表明, 本文所提模型能够有效提高预测精度且在进行短期负荷预测中具有有效性。

关键词: 麻雀搜索算法 (SSA); 长短期记忆神经网络 (LSTM); 组合预测; 预测精度

DOI: 10.12067/ATEEE2107053

文章编号: 1003-3076(2022)06-0071-09

中图分类号: TM715; TP183

1 引言

电力系统负荷预测可对未来一段时间的电力需求进行估计, 从而根据负荷预测结果来安排机组组合计划、发电计划、联络线交换计划, 组织电力现货交易。因此, 准确的电力负荷预测对于电力系统安全、经济、高效地运行有着重要的意义^[1]。短期电力负荷预测主要是指对未来一天、一周甚至几周时间内的用电负荷进行预测, 是电网日常运营的重要组成部分。

对于短期电力负荷预测的研究方法, 大致分为两类, 包括传统电力负荷预测方法^[2-12]和机器学习算法^[13-16]模型预测方法。基于当下新型用电环境与影响用电因素复杂多样化的特点, 机器学习算法模型成为学者们在电力负荷预测领域研究的焦点。

随着人工神经网络 (Artificial Neural Network, ANN) 的迅速发展, 其各种模型及其变体被广泛应用于负荷预测领域, 其中最具有代表性的是反向传播神经网络 (Back Propagation, BP)。文献[16, 17]针对传统 BP 算法模型易陷入局部极小值的问题, 分别从梯度下降角度和改进神经网络的连接权值角

度进行寻优, 优化了网络性能并提高了预测精度; 文献[18]对用电数据进行点预测与区间预测, 其通过小波变换以及改进粒子群优化 BP 神经网络模型进行的点预测和其构建的区间预测模型都较传统 BP 模型在精度上有所提高。

循环神经网络 (Recurrent Neural Networks, RNN) 通过将数据的时序性与网络设计相结合, 有效地突破了 ANN 无法利用数据间时序依赖关系进行预测的弊端, 但是 RNN 在处理具有长时间跨度的非线性数据上时, 又产生了梯度消失与梯度爆炸的问题。对此 Hochreiter 和 Schmidhuber^[19]提出了长短期记忆 (Long Short-Term Memory, LSTM) 神经网络对其进行改进, 有效地解决了数据间的长期时序依赖问题。文献[20-23]分别采用了张量深度学习框架、双层 LSTM 神经网络、将 LSTM 的输出层与全连接层进行合并以及结合支持向量回归 (Support Vector Regression, SVR) 与 LSTM 构建混合模型的方式, 在 LSTM 模型的搭建上分别进行不同的改进, 以获得较为精确的预测结果。文献[24]将 LSTM 的输入数据通过卷积神经网络 (Convolutional Neural

收稿日期: 2021-07-26

基金项目: 国家重点研发计划智能机器人专项子课题 (2019YFB1312102)、河北省自然科学基金 (F2019202364)

作者简介: 赵婧宇 (1995-), 女, 河北籍, 硕士研究生, 研究方向为信息感知与机器学习;

池 越 (1977-), 男, 河北籍, 副教授, 博士, 研究方向为信息感知与机器学习 (通信作者)。

Network, CNN) 去融合多尺度特征向量进行改进。文献[25,26]分别通过粒子群算法(Particle Swarm Optimization, PSO)及改进算法对 LSTM 网络参数进行寻优,在人为设定网络参数与网络模型的预测精度方面较之前 LSTM 的提升算法均有显著的提高。

综上所述并结合现有算法,本文提出基于麻雀搜索算法-长短期记忆(Sparrow Search Algorithm-Long Short-Term Memory, SSA-LSTM)模型进行短期电力负荷预测,用以解决 LSTM 网络参数选取随机性大、选择困难的问题,同时提高负荷预测的精度。首先对历史用电负荷数据以及气候、节假日等影响因素数据进行预处理,然后构建麻雀群体,将待优化参数与麻雀种群维度相对应,将处理好的数据输入到模型中,在模型的训练过程中通过麻雀搜索算法(Sparrow Search Algorithm, SSA)进行参数寻优,将得到的最优参数用以搭建预测模型进行预测。与传统预测模型相比较,SSA-LSTM 模型在一定程度上提高了预测的准确度,相较于 PSO 优化的 LSTM 模型,SSA-LSTM 模型能够不受季节变化的影响,模型的预测精度更高。

2 预测模型原理

2.1 LSTM 原理

图1为 LSTM 的基本单元,LSTM 通过对其遗忘门、输入门、输出门等门控单元进行有效组合可以实现信息的保护和当前状态的更新,更新规则如式(4)所示。门控单元的实现如式(1)~式(6)所示:

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

$$i_t = \sigma(W_i \times [h_{t-1}, z_t] + b_i) \quad (2)$$

$$\hat{C}_t = \tanh(W_C \times [h_{t-1}, z_t] + b_C) \quad (3)$$

$$C_t = f_t \times C_{t-1} + i_t \times \hat{C}_t \quad (4)$$

$$o_t = \sigma(W_o \times [h_{t-1}, z_t] + b_o) \quad (5)$$

$$h_t = o_t \times \tanh C_t \quad (6)$$

式中, z 为输入向量; h 为输出向量; f 为遗忘门; i 为输入门; o 为输出门; C 为单元状态; t 为时刻; σ 、 \tanh 分别为 sigmoid、tanh 激活函数; W 为权重; b 为偏差矩阵。

2.2 多输入多输出 LSTM 网络结构

图2为本文构建的 LSTM 的多输入多输出神经网络模型,通过截取预测日前 N 天的用电负荷数据,与预测日当天的天气等相关影响特征构建输入向量;构建包含两层隐藏层的堆叠 LSTM 模型,使得

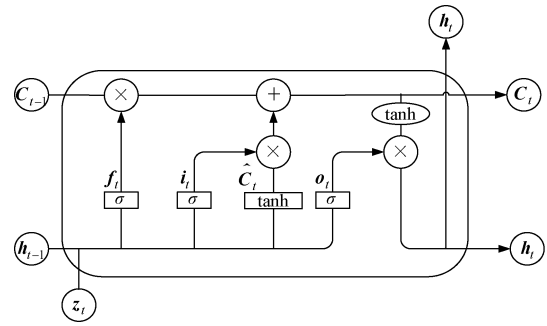


图1 LSTM 结构示意图

Fig.1 Structure diagram of LSTM

网络能够对输入数据进行深度学习;通过将之前时刻输出负荷值在时间轴上进行传递,可以有效地利用历史负荷数据进行当前负荷数据的预测。但是时间窗口 N 的大小、隐藏层所包含的基本单元个数,以及为了获取最小损失函数需要循环迭代次数、每次输入的样本数量都对预测的输出数据精度产生一定的影响,而每次通过手动调参又会浪费大量的时间且不一定可以调得最优参数,因此根据所需优化的超参数个数构建麻雀种群粒子维度,采用 SSA 算法对以上参数进行寻优。




图2 LSTM 神经网络结构图

Fig.2 Structure diagram of LSTM neural network

2.3 SSA 算法原理

麻雀搜索算法是由薛建凯^[27]提出的新型群智能优化技术,其灵感来源于麻雀种群中的觅食行为和反捕食行为。算法将麻雀的种群分为发现者和加入者,通过构建的适应度函数对麻雀的适应度值进行计算,以此来实现麻雀个体之间的角色、位置变换,有效地避免了传统优化算法易陷入局部最优解的问题。

$$\mathbf{X} = \begin{bmatrix} x_1^1 & x_1^2 & \cdots & x_1^d \\ x_2^1 & x_2^2 & \cdots & x_2^d \\ \vdots & \vdots & \ddots & \vdots \\ x_n^1 & x_n^2 & \cdots & x_n^d \end{bmatrix} \quad (7)$$

式中, \mathbf{X} 为随机初始化的麻雀种群; x 为麻雀个体; d 为种群的维数, 在数值上与 LSTM 神经网络待优化参数个数相同; n 为麻雀的数量。

$$\mathbf{G}_x = \begin{bmatrix} g([x_1^1 & x_1^2 & \cdots & x_1^d]) \\ g([x_2^1 & x_2^2 & \cdots & x_2^d]) \\ \vdots \\ g([x_n^1 & x_n^2 & \cdots & x_n^d]) \end{bmatrix} \quad (8)$$

式中, \mathbf{G}_x 为适应度矩阵; g 为麻雀的适应度值, 通过预测负荷数据与原始负荷数据的均方根 (Root Mean Squared Error, RMSE) 进行计算。

$$\mathbf{X}_{i,j}^{iter+1} = \begin{cases} \mathbf{X}_{i,j} \cdot \exp\left(-\frac{i}{\alpha \cdot iter_{\max}}\right) & R_2 < ST \\ \mathbf{X}_{i,j} + QL & R_2 > ST \end{cases} \quad (9)$$

式中, $iter$ 为当前迭代数; $iter_{\max}$ 为最大迭代次数; $\mathbf{X}_{i,j}$ 为第 i 个麻雀在第 j 维中的位置信息, $j=1, 2, 3, \dots, d$; $\alpha \in (0, 1]$; R_2 和 ST 分别为预警值和安全值, 其中 $R_2 \in (0, 1]$, $ST \in [0.5, 1]$, 发现者发现了捕食者, 会立即发出报警信号, 如果报警值大于安全阈值, 发现者就会根据式(9)进行位置更新, 否则就继续进行之前的搜索工作; Q 为随机数, 服从正态分布; L 为 $1 \times d$ 且每个元素都为 1 的矩阵。

$$\mathbf{X}_{i,j}^{iter+1} = \begin{cases} Q \cdot \exp\left(\frac{\mathbf{X}_{\text{worst}} - \mathbf{X}_{i,j}^{iter}}{i^2}\right) & i > \frac{n}{2} \\ \mathbf{X}_{i,j}^{iter+1} + |\mathbf{X}_{i,j} - \mathbf{X}_p^{iter+1}| \mathbf{A}^+ \mathbf{L} & \text{其他} \end{cases} \quad (10)$$

式中, \mathbf{X}_p 为当前发现者所占据的最优位置; $\mathbf{X}_{\text{worst}}$ 为当前全局最差的位置; \mathbf{A} 为每个元素随机赋值为 1 或 -1 的矩阵, 并且 $\mathbf{A}^+ = \mathbf{A}^T(\mathbf{A}\mathbf{A}^T)^{-1}$ 。加入者在觅食过程中会随时监视着发现者, 一旦发现者发现了更好的食物, 加入者会立刻与之争抢, 如果加入者赢了, 那么它们就将该发现者的食物据为己有, 否则继续觅食。加入者按照式(10)进行位置更新, 根据条件可知, 当适应度较低的加入者没有获得食物时, 就会进行位置变换, 以获取更多的食物。

$$\mathbf{X}_{i,j}^{iter+1} = \begin{cases} \mathbf{X}_{\text{best}}^{iter} + \beta |\mathbf{X}_{i,j}^{iter} - \mathbf{X}_{\text{best}}^{iter}| & f_i < f_g \\ \mathbf{X}_{i,j}^{iter} + K \left[\frac{|\mathbf{X}_{i,j}^{iter} - \mathbf{X}_{\text{worst}}^{iter}|}{(f_i - f_w) + \varepsilon} \right] & f_i = f_g \end{cases} \quad (11)$$

式中, \mathbf{X}_{best} 为当前全局最优位置; β 为步长控制参数, 服从 $N(0, 1)$ 分布; $K \in [-1, 1]$; f_i 为第 i 只麻雀的适应度值; f_g 为全局最佳适应值; f_w 为全局最差适应值; ε 为避免分母出现零而设置的常数。随机初始化的发现者与加入者根据式(11)去争抢食物资源并进行位置更新, 直到达到最大迭代次数, 找出全局适应度值最高的麻雀为全局最优解。

2.4 SSA-LSTM 总体流程

LSTM 网络结构的参数选择对负荷预测的准确性有很大的影响, 因此对 LSTM 网络结构的关键参数进行寻优是十分必要的。麻雀搜索算法在收敛度和精度方面都表现出良好的性能, 在处理非线性和多变量问题时也有一定的优势, 因此本文采用麻雀搜索算法对 LSTM 神经网络结构的关键参数进行寻优。本文选取 LSTM 网络模型中的时间窗口大小、批处理大小和隐藏层单元数作为优化对象, 用以架构麻雀搜索算法的粒子维度。模型整体结构如图 3 所示, 模型优化过程如下:

(1) 初始化: 以 LSTM 网络的时间窗口大小、批处理大小和隐藏层单元数作为优化对象, 确定麻雀种群大小、迭代次数、初始安全阈值, 初始化 SSA 优化算法。

(2) 适应值: 利用 LSTM 算法的预测值和样本数据的均方根来确定每只麻雀的适应值。

(3) 更新: 利用式(9)~式(11)更新麻雀位置, 得到麻雀种群的适应度值, 并对种群中最优个体位置和全局最优位置值进行保存。

(4) 迭代: 判断是否满足终止条件或者是否达到更新迭代次数的最大值。如果是, 则退出循环并返回最优个体解, 即确定网络结构最优参数, 否则继续循环步骤(3)。

(5) 优化结果输出: 以 SSA 算法输出的最优粒子值作为 LSTM 的时间窗口大小、批处理大小和隐藏层单元数。

3 算例分析

3.1 数据选取

实验基于 2016 年电工杯 A 题所提供的数据集, 该数据集包含了 2012 年 1 月 1 日至 2015 年 1 月 10 日的用电数据以及气象数据, 该用电负荷数据以 15 min 为粒度, 每天一共 96 个采集点数据, 实验选取距今较近且数据较全的 2014 年负荷数据以及气象数据进行实验。

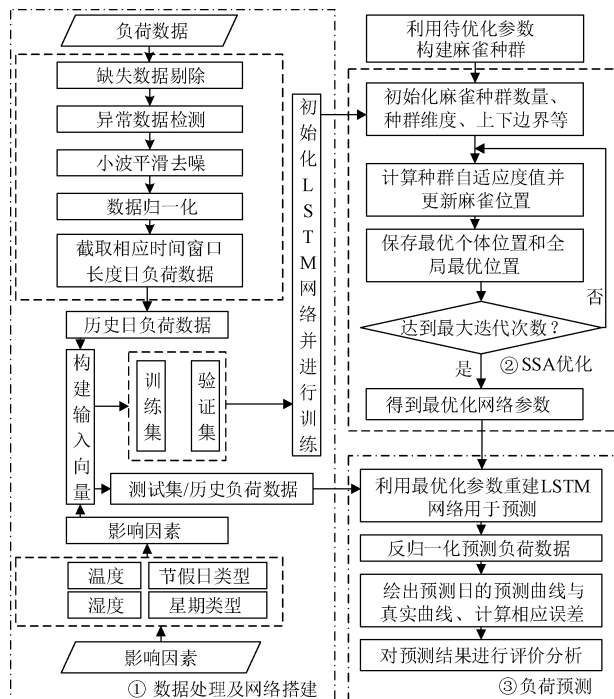


图3 预测模型整体结构

Fig.3 Forecast model overall structure

3.2 数据预处理

3.2.1 数据清洗

数据的质量为预测精度提供了有力的保障,但是在数据的采集过程中也存在着一些异常数据。对于缺失的负荷数据先用0值进行填充,此时缺失数据点被处理成了异常数据点,然后统一对数据集中的异常数据项进行辨别和修正。


负荷曲线中的异常数据通常表现为数据项取值突然升高或者降低,对这些异常数据运用均值填补法进行修正,公式如下:

$$y_{(i,s)} = \frac{\sum_{i=1}^a y_{(i-a,s)} + \sum_{i=1}^b y_{(i+b,s)}}{a+b} \quad (12)$$


式中, a 、 b 分别为向前与向后所取的天数,一般取2~4; $y_{(i,s)}$ 为第*i*天的第*s*个采样点的负荷数据。某条负荷曲线采样点缺失数据与异常数据的处理如图4所示。

3.2.2 数据去噪

在数据采集过程中由于受到各种因素的影响,采集到的历史负荷数据往往是在真实的负荷值上叠加了一定的随机噪声,这些噪声会引起预测结果的偏差,因此对原始负荷数据进行了去噪处理。实验选取 Symlet 小波函数对数据进行去噪处理,部分去噪后数据与原始数据对比曲线如图5所示。



(a) 某采样点缺失数据的补全



(b) 某采样点异常数据的修正

图4 缺失数据与异常数据的处理

Fig.4 Handling of missing data and abnormal data




图5 数据去噪对比图

Fig.5 Comparison chart of data denoising

3.2.3 数据归一化处理

由于用电负荷数据的数量级较大,会对神经网络的训练和计算效率产生影响,同时也为了提升算法的收敛速率,因此将数据进行归一化处理。本文采用 min-max 标准化方法将原始用电负荷数据归一化到[0,1]之间,表达式如下:

$$y'_i = \frac{y_i - y_{\min}}{y_{\max} - y_{\min}} \quad (13)$$

式中, y_i 为去噪后的负荷数据; y'_i 为归一化后的数据作为模型的输入值; y_{\max} 、 y_{\min} 分别为数据中的最大值、最小值。

3.2.4 输入向量的构建

电力负荷数据是一种非线性、非平稳的时间序列,其需求量与许多影响因素有关,研究选取对负荷预测影响较大的平均温度、最高温度、最低温度、湿度、日期类型以及是否节假日等作为负荷预测的影响因素,结合前 N 日负荷序列的 96 点采样数据进行输入向量的构建。其中需对工作日、节假日等数据进行量化处理,例如对工作日置 0 节假日置 1。

本文构造的输入向量为待预测日前 N 天的负荷数据 $[Y_{(pre-N,1)}, Y_{(pre-N,2)}, \cdots, Y_{(pre-1,95)}, Y_{(pre-1,96)}]$ 并结合待预测日的影响因素,将其输入到神经网络中,网络输出为待预测日的 96 点负荷数据 $[Y_{(pre,1)}, Y_{(pre,2)}, \cdots, Y_{(pre,95)}, Y_{(pre,96)}]$ 。

3.3 预测精度评价指标

使用平均绝对误差 (Mean Absolute Error, MAE)、平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE)、均方根误差 (Root Mean Squared Error, RMSE) 和平均误差 (Mean Error, ME) 来评估模型,如式 (14)~式 (17) 所示:

$$MAE(y_i, \hat{y}) = \frac{1}{m} \sum_1^m |y_i - \hat{y}| \tag{14}$$

$$MAPE(y_i, \hat{y}) = \frac{1}{m} \sum_1^m \frac{|y_i - \hat{y}|}{|y_i|} \tag{15}$$

$$RMSE(y_i, \hat{y}) = \sqrt{\frac{1}{m} \sum_1^m (y_i - \hat{y})^2} \tag{16}$$

$$ME(y_i, \hat{y}) = \frac{1}{m} \sum_1^m (y_i - \hat{y}) \approx 0.8RMSE \tag{17}$$

式中, y_i 为去噪后负荷数据的真实值; \hat{y} 为预测值; m 为待预测的数据个数。通过 MAE 来反映预测误差的实际情况,MAPE 来评估模型精度,RMSE 来评估预测精度,ME 来评估预测模型的整体性偏差。MAE、MAPE、RMSE 和 ME 的值越小,表明预测模型的精度越高,预测效果越好。

同时本文以 RMSE 构建 SSA 的适应度函数,求解最佳粒子。同时通过评价指标对 LSTM、PSO-LSTM、BP、PSO-BP、SSA-BP、SSA-LSTM 等模型进行对比评估,验证本文所提出模型的先进性。

3.4 实验分析与负荷预测

实验模型在 python3.8 编译器下搭建,在 2.40 GHz Intel(R) Core(TM) /i5-9300HF CPU /GeForce GTX 1650-GPU/8 GB 内存的计算机上运行。

3.4.1 各个季节单日负荷预测

因各个季节气候不同,因此用电量也会有所变

化,因此对四个季节分别建立模型并进行参数寻优。按照地球公转原则,截取 2014 年的 3~5 月为春季数据集,6~8 月为夏季数据集,9~11 月为秋季数据集,因数据集中只收录到 2015 年 1 月数据,故选取 2013 年 12 月、2014 年 1 月、2 月为冬季数据集分别进行实验。四个数据集中的数据 60% 用于训练,20% 用于验证,20% 用于预测。

经实验发现,在训练初期模型的预测精度随着网络层数的增加而提高,但是当 LSTM 神经网络层数大于 2 层时,模型的预测精度未发生明显提高且整体优化时间成倍递增,因此选择 LSTM 的网络层数为 2 层,Dropout 为 0.2,在 LSTM 最后加入一个全连接层,神经单元数量为 96 即预测的 96 个负荷数据,学习率为 0.001。经网络模型寻优出来的四个季节模型参数见表 1。

表 1 各季节模型参数

Tab.1 Model parameters for each season				
季节	春季	夏季	秋季	冬季
时间窗口 N /天	6	6	4	5
Epoch	400	700	700	500
Batch_size	220	300	500	200
Hidden_1	128	128	128	128
Hidden_2	512	256	256	512

利用寻优出来的参数进行模型的搭建,然后随机选取预测日进行负荷预测。实验分别对 2014 年 2 月 21 日、5 月 26 日、8 月 28 日、11 月 27 日的负荷数据进行了预测,真实值与预测值对比结果如图 6 所示,每 15 min 为 1 个采样点。通过预测结果获得的 MAE、RMSE、MAPE 与 ME 见表 2。

表 2 2014 年预测结果 MAE、MAPE、RMSE、ME 对比

Tab.2 Comparison of MAE, MAPE, RMSE and ME predicted results in 2014				
预测日	2 月 21 日	5 月 26 日	8 月 28 日	11 月 27 日
MAE/MW	94.78	114.8	90.12	105.16
MAPE	1.95	1.58	1.02	1.83
RMSE/MW	114.18	136.05	119.88	120.44
ME/MW	91.34	108.84	95.90	96.35

从图 6 可以看出,利用经 SSA 算法优化出的参数重新训练出的模型,在四个预测日的预测效果都比较好,与真实值更为接近,通过图 6(c) 可以看出,预测曲线几乎与真实曲线完全重合,有效地预测了短期内日负荷量未来的变化趋势,精准地把握了负荷变化的规律。由表 2 可得,从误差的实际情况来看,MAE 控制在 90.12~114.8 MW 之间;从预测精




图6 预测结果图

Fig.6 Forecast result chart

度来看, $RMSE$ 控制在 114.18~136.05 MW 之间;从评估模型精度的角度来看, $MAPE$ 控制在 1.02%~1.95% 之间。综上所述, 本文所提算法模型具有较

高的预测精度。

3.4.2 模型对比分析

图7为四个预测日分别在 LSTM、PSO-LSTM、BP、PSO-BP、SSA-BP、SSA-LSTM 六种预测模型下的结果对比, 表3为六种模型的预测指标。

从图7可以看出, 通过 SSA-LSTM 模型预测出的用电负荷与真实用电负荷数据之间的拟合程度在随机选取的四个预测日中都较其他5种模型预测效果更好, 与真实值的拟合程度更高。

表3和表4为四个预测日分别在六种算法模型下的预测结果对比, 通过表3和表4可以看出, SSA-LSTM 模型预测精度的误差在 1.02%~1.95% 之间, 而目前普遍应用的 PSO-LSTM 算法模型预测精度的误差在 1.43%~2.06% 之间, 提升了 0.09%~0.41%。且就六种对比算法整体拟合效果较好的图6(c)来看, SSA-LSTM 的 $MAPE$ 较目前存在的改进算法模型 PSO-BP、PSO-LSTM 分别提升了 0.82%、0.41%, 较 SSA 优化的对比算法模型 SSA-BP 提升了 0.42%, 表现出了较好的预测模型精度; MAE 较其他三种优化算法模型分别降低了 62.53 MW、44.43 MW、31 MW, 较好地降低了预测误差; $RMSE$ 相较于其他三种优化算法模型分别降低了 83.8 MW、60.54 MW、31.08 MW, 表明所提算法模型在预测精度方面有较大的提升; 通过预测模型的 ME 来看, 模型整体性能稳定, 未出现较大偏差。

此外, 对比表3和表4中 SSA-BP 的 MAE 、 $MAPE$ 、 $RMSE$ 、 ME 评价指标, 可以看出实验所搭建的 SSA 优化 BP 神经网络对比算法模型较 PSO-BP 神经网络模型有了改进, 这表明通过 SSA 算法来寻优网络参数进行预测是优于目前应用较多的 PSO 寻优算法模型的。

由此可见, 本文提出的 SSA 优化 LSTM 的多输出神经网络模型能够将历史用电负荷与相关影响因素等数据与网络结构深入匹配, 较好地学习了历史负荷变化的规律, 能够对未来的用电负荷做出更为准确的预测。

4 结论

本文提出 SSA-LSTM 模型, 并结合 2016 年电工杯数学建模竞赛数据进行短期负荷预测, 通过算例分析得到以下结论:

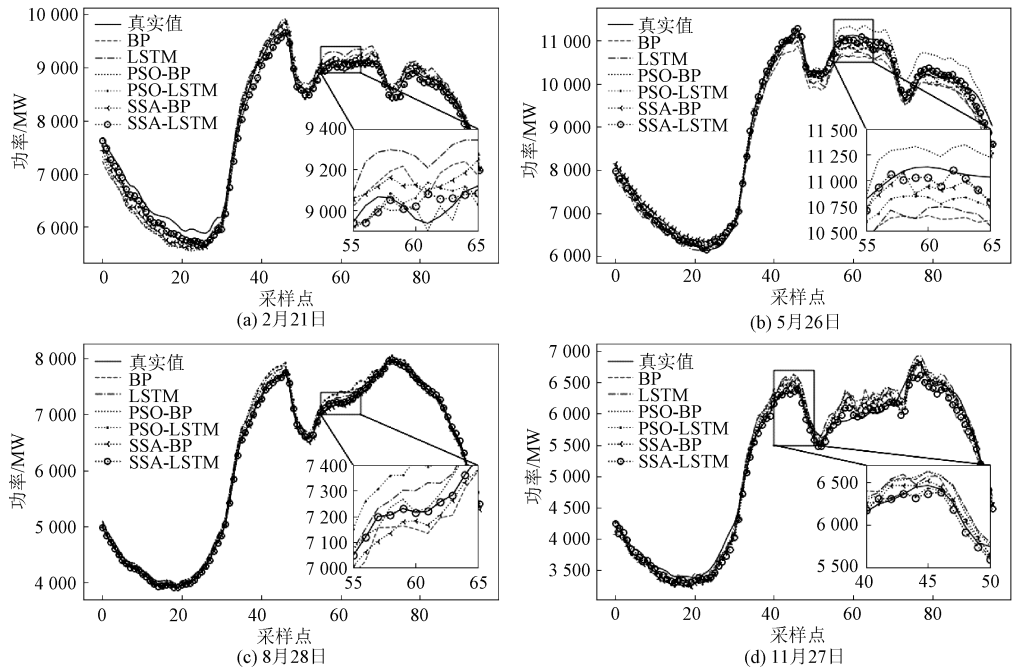


图 7 四个预测日负荷预测结果对比
Fig.7 Comparison of four daily load forecasting results

表 3 对比模型的 MAE、MAPE
Tab.3 MAE and MAPE of comparison models

对比模型	2014. 2. 21		2014. 5. 26		2014. 8. 28		2014. 11. 27	
	MAE/MW	MAPE(%)	MAE/MW	MAPE(%)	MAE/MW	MAPE(%)	MAE/MW	MAPE(%)
BP	139.76	2.56	191.15	2.68	255.47	2.60	142.99	2.54
LSTM	131.91	2.44	174.59	2.25	220.02	2.32	116.63	2.24
PSO-BP	121.61	2.30	163.32	2.39	152.65	1.84	112.87	2.17
PSO-LSTM	99.19	2.06	146.88	2.03	134.55	1.43	110.05	1.96
SSA-BP	108.50	2.25	164.44	2.29	121.12	1.46	118.77	2.02
SSA-LSTM	94.78	1.95	114.8	1.58	90.12	1.02	105.16	1.83

表 4 对比模型的 ME、RMSE
Tab.4 ME and RMSE of comparison models

对比模型	(单位:MW)							
	2月21日		5月26日		8月28日		11月27日	
	ME	RMSE	ME	RMSE	ME	RMSE	ME	RMSE
BP	141.74	177.18	193.70	242.12	246.64	308.30	128.79	160.99
LSTM	128.10	160.12	150.43	188.04	216.57	270.71	112.57	140.71
PSO-BP	119.32	149.15	184.78	230.98	162.94	203.68	108.67	135.84
PSO-LSTM	102.79	128.49	136.84	171.05	144.34	180.42	102.30	127.87
SSA-BP	103.23	129.04	160.29	200.36	120.77	150.96	112.18	140.23
SSA-LSTM	91.34	114.18	108.84	136.05	95.90	119.88	96.35	120.44

(1)通过对用电负荷数据集按照季节进行划分,选取预测日的温度、湿度以及节假日和工作日类型并结合历史用电数据进行输入序列的构建,并训练相应的模型,充分考虑了相关影响因素对负荷预测的影响,有效地提高了预测精度。

(2)本文通过 SSA 进行参数寻优并构建 LSTM 预测网络,使得输入数据与网络结构深入匹配,有效地解决了人工调参的耗时长且预测效果不佳的问题,并提高了预测精度。

参考文献 (References):

- [1] 孔祥玉, 郑锋, 鄂志君, 等 (Kong Xiangyu, Zheng Feng, E Zhijun, et al.). 基于深度信念网络的短期负荷预测方法 (Short-term load forecasting based on deep belief network) [J]. 电力系统自动化 (Automation of Electric Power Systems), 2018, 42 (5): 133-139.
- [2] 赵龙波, 马尽文 (Zhao Longbo, Ma Jinwen). GPFR 混合模型的动态模型选择算法 (Dynamic model selection algorithm for GPFR mixtures) [J]. 信号处理 (Journal of Signal Processing), 2019, 35 (5): 786-794.
- [3] 杨正钊, 田勇, 张广涛, 等 (Yang Zhengling, Tian Yong, Zhang Guangtao, et al.). 相似日短期负荷预测的非线性理论基础与改进 (Nonlinear theoretical foundation and improvement of similar days method for short term load forecasting) [J]. 电网技术 (Power System Technology), 2006, 30 (6): 63-66.
- [4] Dhaval B, Deshpande A. Short-term load forecasting with using multiple linear regression [J]. International Journal of Electrical and Computer Engineering, 2020, 10 (4): 3911-3917.
- [5] Amato U, Antoniadis A, Feis I D, et al. Forecasting high resolution electricity demand data with additive models including smooth and jagged components [J]. International Journal of Forecasting, 2021, 37 (1): 171-185.
- [6] 马冬芬 (Ma Dongfen). Short-term load forecasting based on variable weighted synthesis of different kernel SVM [J]. Statistics and Applications, 2020, 9 (1): 73-80.
- [7] Li R, Jiang P, Yang H, et al. A novel hybrid forecasting scheme for electricity demand time series [J]. Sustainable Cities and Society, 2020, 55: 1-11.
- [8] Mb A, Jadm B, Tmos B, et al. Multiple households very short-term load forecasting using Bayesian networks [J]. Electric Power Systems Research, 2020, 189: 1-7.
- [9] Faysal M, Islam M J, Murad M M, et al. Electrical load forecasting using fuzzy system [J]. Journal of Computer and Communications, 2019, 7 (9): 27-37.
- [10] Yang Y, Che J, Deng C, et al. Sequential grid approach based support vector regression for short-term electric load forecasting [J]. Applied Energy, 2019, 238: 1010-1021.
- [11] 程志友, 丁柏宏, 余国晓 (Cheng Zhiyou, Ding Baihong, Yu Guoxiao). 基于 IPSO-LSVM 的短期负荷预测方法 (Short-term load forecasting method based on IPSO-LSVM) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2020, 39 (5): 41-48.
- [12] 曲正伟, 张坤, 王云静, 等 (Qu Zhengwei, Zhang Kun, Wang Yunjing, et al.). 基于 PSO-OMP 优化的 WD-ASD 超短期负荷预测 (Short-term load forecasting based on WD-ASD optimized by PSO-OMP) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2017, 36 (12): 39-45.
- [13] Zhang L, Liu H, He H. Prediction of intrinsically disordered proteins using machine learning algorithms based on fuzzy entropy feature [J]. Algorithms, 2021, 14 (4): 102-117.
- [14] Li C. A fuzzy theory-based machine learning method for workdays and weekends short-term load forecasting [J]. Energy and Buildings, 2021, 245: 1-15.
- [15] Guo W, Che L, Shahidehpour M, et al. Machine-learning based methods in short-term load forecasting [J]. The Electricity Journal, 2021, 34 (1): 1-7.
- [16] 隋惠惠 (Sui Huihui). 基于 BP 神经网络的短期电力负荷预测的研究 (Research on short-term electric load forecasting based on BP neural network) [D]. 哈尔滨: 哈尔滨工业大学 (Harbin: Harbin Institute of Technology), 2015.
- [17] 赵晋晔 (Zhao Jinye). 基于改进 PSO-BP 神经网络模型的短期电力负荷预测研究 (Study of short-term power load forecasting based on modified PSO-BP neural network model) [D]. 沈阳: 东北大学 (Shenyang: Northeastern University), 2009.
- [18] 李昌海 (Li Changhai). 基于机器学习算法的短期电力负荷预测研究 (Short-term load forecasting based on machine learning algorithm) [D]. 成都: 电子科技大学 (Chengdu: School of Mechanical and Electrical Engineering), 2020.
- [19] Hochreiter S, Schmidhuber J. Long short-term memory [J]. Neural Computation, 1997, 9 (8): 1735-1780.
- [20] 陈亮, 王震, 王刚, 等 (Chen Liang, Wang Zhen, Wang Gang, et al.). 深度学习框架下 LSTM 网络在短期电力负荷预测中的应用 (Application of LSTM networks in short-term power load forecasting under the deep learning framework) [J]. 电力信息与通信技术 (Electric Power Information and Communication Technology), 2017, 15 (5): 8-11.
- [21] Tang D, Li C, Ji X, et al. Power load forecasting using a refined LSTM [A]. Proceedings of the 2019 11th International Conference on Machine Learning and Computing [C]. Zhuhai, China, 2019. 104-108.
- [22] Kwon B S, Park R J, Song K B. Short-term load forecasting based on deep neural networks using LSTM layer [J]. Journal of Electrical Engineering & Technology, 2020, 15 (4): 1501-1509.

- [23] Moradzadeh A, Zakeri S, Shoaran M, et al. Short-term load forecasting of microgrid via hybrid support vector regression and long short-term memory algorithms [J]. Sustainability, 2020, 12 (17): 1-17.
- [24] Guo X, Zhao Q, Zheng D, et al. A short-term load forecasting model of multi-scale CNN-LSTM hybrid neural network considering the real-time electricity price [J]. Energy Reports, 2020, 6 (9): 1046-1053.
- [25] 刘博 (Liu Bo). 基于 PSO-LSTM 算法的短期电力负荷预测应用研究 (Research of short-term power load forecasting based on PSO-LSTM algorithm) [D]. 吉林: 吉林大学 (Jilin: Jilin University), 2020.
- [26] 魏腾飞, 潘庭龙 (Wei Tengfei, Pan Tinglong). 基于改进 PSO 优化 LSTM 网络的短期电力负荷预测 (Short-term power load forecasting based on LSTM neural network optimized by improved PSO) [J]. 系统仿真学报 (Journal of System Simulation), 2021, 33 (8): 1866-1874.
- [27] 薛建凯 (Xue Jiankai). 一种新型的群智能优化技术的研究与应用: 麻雀搜索算法 (Research and application of a novel swarm intelligence optimization technique: Sparrow search algorithm) [D]. 上海: 东华大学 (Shanghai: Donghua University), 2020.

Short-term load forecasting based on SSA-LSTM model

ZHAO Jing-yu, CHI Yue, ZHOU Ya-tong

(School of Electronics and Information Engineering, Hebei University of Technology, Tianjin 300401, China)

Abstract: Power load forecasting is essentially a time series forecasting problem, which has non-stationarity and complexity of influencing factors. In order to improve the prediction accuracy and solve the problem of large random and difficult selection of long-short term memory (LSTM) neural network parameters, a short-term power load forecasting model (SSA-LSTM) that uses the sparrow search algorithm (SSA) to optimize the parameters of the long-short term memory neural network is proposed. The historical power load data related influencing factor data is used to make load forecasts on the day to be forecasted. First, the historical power load data, weather, holidays and other influencing factors data are preprocessed. Secondly, the processed data is used to train the model, and the parameters of the long-short term memory neural network are optimized with the help of the sparrow search algorithm to better match the input data with the network structure. Finally, load forecasting is performed and other algorithm models are compared for analysis. The results of calculation examples show that the model proposed in this paper can effectively improve the prediction accuracy and is effective in short-term load forecasting.

Key words: sparrow search algorithm (SSA); long-short term memory (LSTM); combination forecasting model; prediction accuracy