

DOI: 10.19783/j.cnki.pspc.210026

基于改进 Apriori 关联分析及 MFOLSTM 算法的短期负荷预测

王凌云¹, 林跃涵¹, 童华敏², 李黄强², 张涛¹

(1. 三峡大学电气与新能源学院, 湖北 宜昌 443002; 2. 国网宜昌供电公司, 湖北 宜昌 443002)

摘要: 电力负荷预测结果的准确性对电力系统安全稳定运行具有重要意义。针对多气象因素影响下的短期负荷预测任务, 提出改进 Apriori 关联度分析及飞蛾火焰优化的长短期记忆神经网络算法的电力负荷短期预测新方法。首先, 提出改进 Apriori 算法分析气象因素与负荷之间的关联程度。依据分析结果除去非必要气象影响因素, 并在此基础上引入人体舒适度评价指标。其次, 将降维后气象数据结合地区负荷数据作为模型输入。最后, 基于长短期记忆神经网络进行短期负荷预测建模, 并结合飞蛾火焰优化算法的全局寻优能力来优化模型。通过对某地区负荷数据协同气象数据进行对比预测试验, 测试结果表明该负荷预测模型能有效提升地区电网短期负荷预测性能。

关键词: 短期负荷预测; Apriori 关联分析; 飞蛾火焰算法; 长短期记忆神经网络

Short-term load forecasting based on improved Apriori correlation analysis and an MFOLSTM algorithm

WANG Lingyun¹, LIN Yuehan¹, TONG Huamin², LI Huangqiang², ZHANG Tao¹

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China;

2. State Grid Yichang Power Supply Company, Yichang 443002, China)

Abstract: The accuracy of power load forecasting results is of great significance to the safe and stable operation of a power system. Considering short-term load forecasting under the influence of multiple meteorological factors, a new short-term power load forecasting method based on an improved Apriori correlation analysis and moth-flame optimization is proposed. First, an improved Apriori algorithm is used to analyze the correlation between meteorological factors and load. Unnecessary meteorological factors are removed from the results, and a human comfort evaluation index is introduced. Secondly, the reduced meteorological data combined with regional load data are used as input to the model. Finally, the short-term load forecasting model is established based on a long short-term memory neural network, and the global optimization model is combined with the moth-flame optimization algorithm. The results show that the load forecasting model can effectively improve the short-term load forecasting performance of a regional power grid.

This work is supported by the National Natural Science Foundation of China (No. 61603212).

Key words: short term load forecasting; Apriori correlation analysis; moth-flame algorithm; long short-term memory neural network

0 引言

负荷预测作为电力系统当中一个传统的研究课题, 准确的预测结果能够指导工作人员合理安排发电机启停时间, 使得电网运行经济效益与社会效益最大化, 保证电网运行的安全可靠^[1-2]。文献[3]

指出负荷预测误差每提高 1%将导致电网运行成本增加一千万英镑。

地区电网负荷容易受到气象因素、经济因素、社会因素等多种因素的影响, 这导致负荷变化具有随机性与不确定性, 因此对数据样本的处理尤为重要。

由于数据种类繁多, 且不同类型数据之间可能存在关联, 若将完整的数据作为输入, 这将延长模型计算时间, 降低预测精度, 所以对数据进行降维

预处理是十分必要的^[4-6]。

除了数据样本的处理, 负荷预测的模型选择也十分重要, 近些年深度学习技术发展迅猛, 神经网络预测模型相较于传统时间序列法、线性回归法等方法, 对非线性负荷数据的拟合精度有着明显提升。2015年, Seyedali Mirjalili 学者受到自然启发提出飞蛾火焰优化算法(Moth-Flame Optimization, MFO), 该算法在非凸函数寻优过程中, 能更广泛探索搜索空间, 并寻找出其中存在全局最优点概率更大的区域。

近年来, 得益于人工智能领域的快速发展, 国内外许多学者将其应用在负荷预测领域, 并取得了丰富的成果。文献[7]采用机器学习方法对能源消耗、供暖或制冷需求等进行预测; 文献[8-9]采用深度学习方法分别对短期母线负荷概率密度以及家庭用户负荷进行预测。上述文献所采用的机器学习方法相较于传统数学统计模型, 能更好地处理复杂度较高的非线性负荷数据, 有效提高模型预测能力。文献[10]通过建立并行局部加权线性回归模型, 解决了海量数据的计算量问题, 但单一的机器学习算法难以对海量数据中蕴含的耦合信息进行有效表达, 从而无法达到理想的预测结果, 因此通过分析多影响因素与负荷变化间的关系, 消除冗余信息, 达到降低数据维度, 减少计算时间, 提高预测精度的目的是十分必要的^[11-13]。

为考虑所提负荷预测研究中关键因素的影响, 本文提出一种改进的 AprioriTid 关联分析方法。AprioriTid 关联分析方法对所引入的气象数据及负荷数据进行关联程度分析, 剔除多余信息, 只引入关联程度较高的气象数据进行负荷预测, 在保证较高预测精度的前提下, 能很好地降低计算难度, 减少预测时间, 保障短期负荷预测任务实时性要求^[14-16]; 其次研究 MFOLSTM 预测模型, 由于每一个长短时记忆神经网络的 cell 里都包含 4 个全连接层, 因此在时间跨度大、网络结构较为复杂的情况下进行训练, 会很耗时, 针对长短时记忆神经网络(Long Short-Term Memory, LSTM)模型的局限性, 提出 MFOLSTM 预测模型, 对原始 LSTM 神经网络最大训练周期以及学习率进行优化, 通过算例对比分析, 在数据降维处理的基础上, 给出不同预测方法的预测结果, 验证所提 AprioriTid-MFOLSTM 方法的可行性以及优越性^[17-19]。

1 Apriori 关联分析及改进

1.1 Apriori 关联规则分析算法

关联规则分析作为数据挖掘当中最活跃的研究方法之一, 其目的在于从一个数据集当中找出不

同类型数据之间的潜在关系, 并直观地表示出来。Apriori 算法在众多关联规则分析算法中综合性能较好, 也是十分常用的一种方法。

Apriori 算法的核心是通过扫描数据集产生候选项及其支持度, 然后通过循环选取频繁项集, 其步骤如下:

1) 预设置最小支持度与最小置信度, 表示为

$$S_{\text{Support}}(A) = P(A) \quad (1)$$

$$S_{\text{Support}}(A, B) = P(A \cap B) \quad (2)$$

项集 A 发生的概率, 项集 A、B 同时发生的概率等均称为关联规则的支持度。

$$C_{\text{Confidence}}(A \Rightarrow B) = P(B | A) \quad (3)$$

$$C_{\text{Confidence}}(A, B \Rightarrow E) = P(E | A \cap B) \quad (4)$$

项集 A 发生的前提下发生 B 的概率, 项集 A、B 同时发生的前提下发生 E 的概率等均称为关联规则的置信度。

2) 通过连接步与剪枝步相结合, 最终得到频繁项集 L_k , 其过程如图 1 所示。

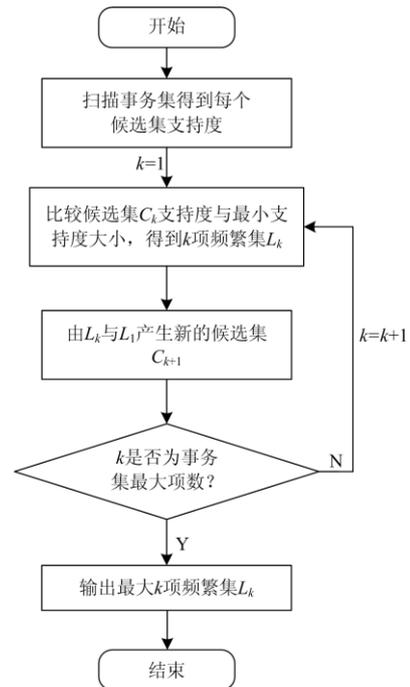


图 1 Apriori 算法流程

Fig. 1 Apriori algorithm flow

连接步: 对于预设的最小支持度, 对单项候选集 C_1 , 除去小于最小支持度的项集得到单项频繁项集 L_1 ; 由 L_1 与自身连接产生两项候选集 C_2 , 同理除去小于最小支持度的项集得到两项频繁项集 L_2 ; 最终由 L_{k-1} 与 L_1 连接产生 k 项候选集 C_k , 并筛选产生最大频繁项集 L_k 。

剪枝步：剪枝步紧随连接步，在得到候选集 C_k 的过程中能很好地减少搜索空间，由于 C_k 的产生是通过 L_{k-1} 与 L_1 连接，根据算法规则，所有非空子集必须是频繁项集，因此在候选集 C_k 中只保留满足该条件的子集。

3) 通过 2) 所产生的频繁项集 L_k ，其中不满足最小支持度的项集均已被剔除，若剩余项集通过置信度计算又满足最小置信度要求，那么就得到了项集中的强关联规则。

1.2 Apriori 的不足及改进

Apriori 算法作为一种经典的数据挖掘类算法，运用到许多领域。但随着负荷预测所需实时气象数据以及各类社会数据的爆炸式增长，Apriori 算法的应用受到了局限，其在应对高维大数据时的表现不尽人意，无法满足负荷预测低时延的要求。因此提出基于 Apriori 改进的 AprioriTid 算法，AprioriTid 算法通过减少扫描次数实现性能优化，例如出现 AB 与 BC 的概率均小于 0.5，则出现 ABC 的概率一定小于 0.5，通过这种方式减少了 I/O 操作时间以及扫描数据库耗时，并通过趋势分析的方法得到对负荷变化趋势有较大的影响的气象种类。

通过对可能影响电力系统负荷变化的多个种类的气象数据与负荷数据进行关联分析，寻找影响电力负荷波动的关键因素，消除多余数据，达到数据降维的目的，提高预测精度，减少预测时间。通过对某地区负荷数据和 6 种气象数据(温度 T ，相对湿度 H ，风速 W ，降雨量 R ，气压 AP ，日照时数 ST)进行关联分析，将置信度高达 75% 及以上数据作为负荷预测输入数据，其步骤如下：

1) 由于人为因素、设备因素等多种因素可能导致负荷历史数据以及气象数据失真问题的产生，这会造成数据相关性大幅度降低，可通过设置阈值，比较数据与相邻数据集的距离来寻找离群点，并通过均值填补的方法对异常数据进行处理^[20-22]。

2) 为了方便比较气象数据变换对负荷数据变化产生的影响，对负荷数据与气象数据进行离散化处理，将每一日负荷数据与前一天进行对比，若负荷上升则表示为 LU ，若负荷下降则表示为 LD ，同理对温度、相对湿度、风速、降雨量、气压、日照时数作同种处理，若无变化则不表示，由此可以得到事务集： $M^* = \{LU, LD, TU, TD, HU, HD, WU, WD, RU, RD, APU, APD, STU, STD\}$ ，有效避免同一事务集当中出现同类数据，第 i 时刻的观测值即为事务 T_i ， T_i 中所包含的数据项均为事务集 M^* 的一个子集。

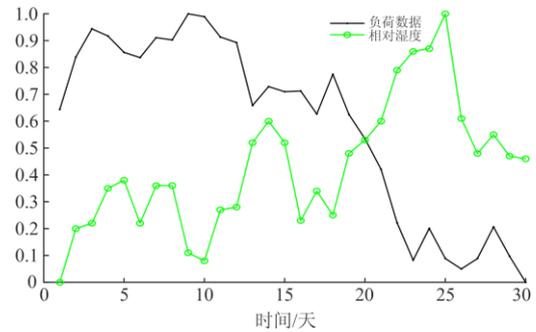
3) 考虑到同类数据相邻日期无变化导致的项

目空缺，算法设置最小支持度为 0.3，最小置信度为 0.75，通过 AprioriTid 算法输出结果如表 1 所示。

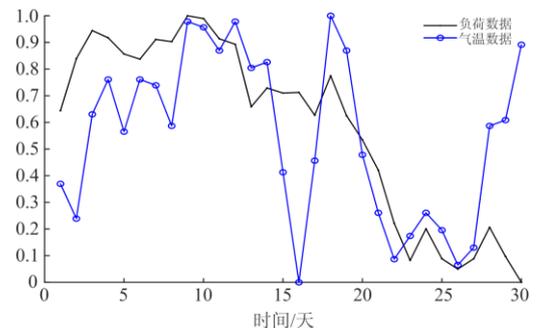
表 1 AprioriTid 算法分析结果

Table 1 Analysis results of AprioriTid algorithm		
关联规则	支持度/%	置信度/%
APD, HU	51.72	88.24
TD, LD	48.28	93.33
HD, LD	34.48	78.33
WU, LD	32.43	76.92

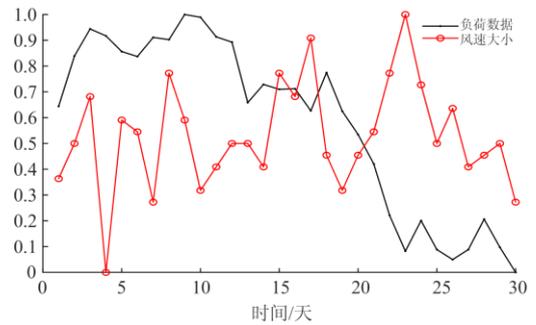
通过 AprioriTid 算法结果可以看出，气压与相对湿度、温度与负荷具有强关联规则，风速与负荷、相对湿度与负荷有较强关联规则，选取该地区 8 月份相对湿度、温度、风速数据与负荷数据进行比对，结果分别如图 2 所示，为方便观测变化趋势将数据进行归一化处理。



(a) 相对湿度与负荷关系



(b) 气温与负荷关系



(c) 风速大小与负荷关系

图 2 气象数据与负荷数据关系

Fig. 2 Relationship between meteorological data and load data

在考虑多气象因素影响时, 通过关联规则分析剔除掉日照时间、气压等关联程度较低数据类型, 本文在关联分析结果的基础上, 考虑到不同类别气象因素之间的耦合效应, 引入人体舒适度评价指标 D , 将对负荷影响较大的温度、相对湿度、风速数据进行组合, 进一步达到数据降维的目的, 人体舒适度一般可描述为式(5)。

$$D = f(T) + g(H) + h(W) \quad (5)$$

式中: D 为人体舒适度评价指标; T 为气温, 单位 $^{\circ}\text{C}$; H 为相对湿度, 用百分数表示; W 为风速, 单位 m/s 。一般将式(6)用作人体舒适度指数计算方法。

$$D = 1.8T + 0.55(1 - H) - 3.2\sqrt{W} + 27 \quad (6)$$

2 MFOLSTM 模型设计与实现

2.1 MFO 优化算法测试

本文提出改进的 LSTM 神经网络, 所采用的飞蛾火焰优化算法并行优化能力强, 总体特性好, 由于非凸函数可能存在局部最优点, MFO 能够广泛地搜索待求空间, 拥有较好的全局寻优能力以及寻优精度, 通过飞蛾火焰优化算法、粒子群优化算法 (Particle Swarm Optimization, PSO)、蝙蝠算法 (Bat Algorithm, BA) 对多峰测试函数(7)进行比对测试, 寻找函数最小值。

$$F_1(x_1, x_2) = -20 \times e^{-0.2 \times \sqrt{\frac{x_1^2 + x_2^2}{2}}} - e^{\frac{\cos(2\pi x_1) + \sin(2\pi x_2)}{2}} + 20 + e \quad (7)$$

测试函数(7)中, F_1 为待优化函数, 两个优化参数分别表示为 x_1, x_2 , 其中 $-1 < x_1, x_2 < 1$ 。

MFO 优化算法及进行比对研究的 PSO 优化算法、BA 优化算法具体参数配置如表 2 所示。

表 2 MFO、PSO、BA 优化算法参数配置

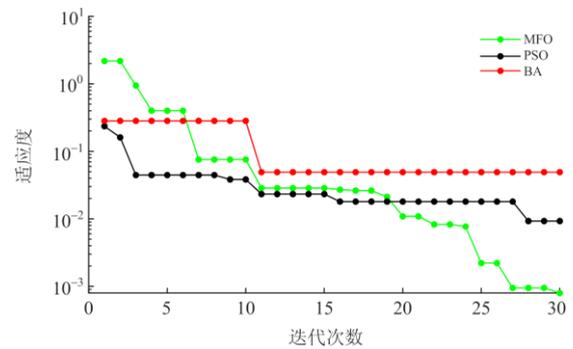
Table 2 Parameter configuration of MFO, PSO and

BA optimization algorithm

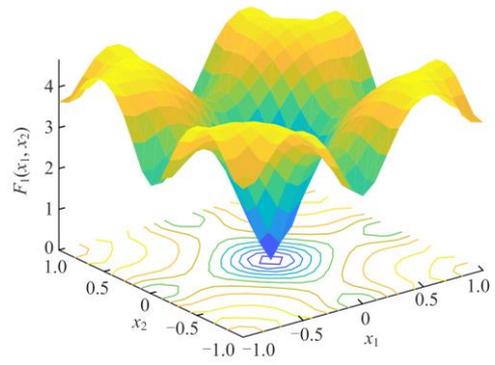
算法	PSO	BA	MFO
群体规模	$N=50$	$N=50$	$N=50$
速度边界	$V_{\min}=-1$		
	$V_{\max}=1$		
位置边界	$lb=-1$	$lb=-1$	$lb=-1$
	$ub=1$	$ub=1$	$ub=1$
学习因子	$c_1=c_2=1.5$		
惯性因子	$W_{\min}=0.4$		
	$W_{\max}=0.9$		
迭代次数	30	30	30
初始响度		$A=0.6$	
初始脉冲率		$r=0$	
频率边界		$Q_{\min}=0$	
		$Q_{\max}=1$	

依据表 2 中的参数对 3 种不同算法进行取值, 对式(7)提供测试函数进行寻优测试, 记录 MFO、PSO、BA 三种算法的优化迭代过程, 其中横坐标为迭代次数, 纵坐标为适应度值, 结果如图 3(a)所示。

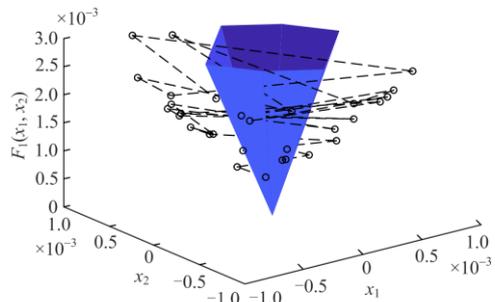
由图 3(b)可知, 对测试函数进行参数寻优, 在迭代 30 次的情况下, PSO 算法寻优到的结果为 0.011 7, MFO 算法寻优到的结果为 2.267×10^{-4} , BA 算法寻优到的结果为 0.049 1, 由于初始种群为随机种群, 因此起始点位置为随机位置, 但从寻优过程可以直观地观测到 MFO 算法下降速度以及寻优结果均优于 PSO 算法和 BA 算法, 因此本文提出采用



(a) MFO、PSO、BA 收敛曲线



(b) 测试函数三维模型



(c) MFO 寻优过程

图 3 MFO 算法测试

Fig. 3 MFO algorithm test

MFO 算法优化 LSTM 神经网络最大训练周期以及学习率, 以提高网络的预测精度以及预测效率, 测试函数三维模型及 MFO 寻优过程如图 3(b)、图 3(c), 其中图 3(c)所示部分为图 3(b)模型最底部, 即全局最优点所在区域。

2.2 LSTM 神经网络数学模型

LSTM 神经网络主要由遗忘门、输入门、输出门构成, 其中, X_t 为模型输入, h_t 为模型输出, C_t 为传递神经元细胞状态, sigmoid 函数以及 tanh 函数为激活函数。遗忘门、输入门、输出门三个逻辑单元以及细胞状态更新过程分别表示为式(8)一式(11)。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (8)$$

$$\begin{cases} i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ C'_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \end{cases} \quad (9)$$

$$\begin{cases} o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t = o_t \cdot \tanh(C_t) \end{cases} \quad (10)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot C'_t \quad (11)$$

式中, $W_f, W_i, W_c, W_o, b_f, b_i, b_c, b_o$ 为神经网络参数。遗忘门的作用是用来忘记信息的, 它决定了细胞状态 C_{t-1} 中哪些信息被遗忘; 输入门的作用是决定输入信息 x_t, h_{t-1} 中哪些信息被保留; 细胞更新过程就是根据遗忘门与输入门输出 f_t, i_t, C'_t 来更新细胞状态; 输出门的作用是将输出信号 h_t 输出并传递到下一阶段, 神经网络模型如图 4 所示。

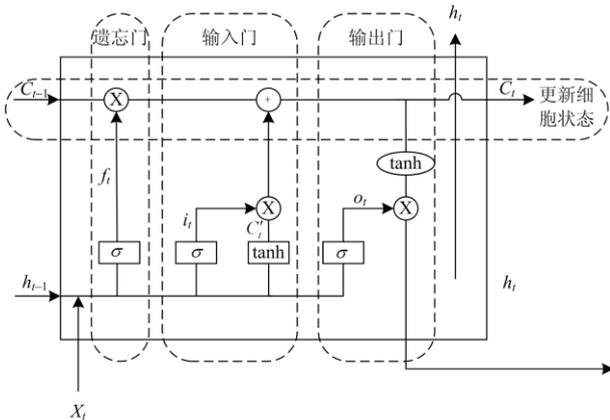


图 4 LSTM 模型结构

Fig. 4 LSTM model structure

2.3 MFOLSTM 预测

本文提出的 MFOLSTM 负荷预测步骤如下:

1) 数据预处理。通过对负荷数据及气象数据进行扫描, 完成异常数据识别替换, 通常可采用平均值修正的方法, 并对处理后数据进行归一化处理,

本文采用最大-最小归一化法, 以便所有的输入数据在可比较的范围内, 归一化后的数值 w' 为

$$w' = \frac{w - w_{\min}}{w_{\max} - w_{\min}} \quad (12)$$

式中: w_{\max} 与 w_{\min} 分别为数组当中最大最小值; w 为待归一化的数值。再通过 AprioriTid 关联分析确定气象数据种类, 构建 MFOLSTM 模型数据输入集。

2) 确定待优化的 LSTM 模型自适应度函数, 本文选取 LSTM 预测均方根误差函数作为自适应度函数, 为提高 LSTM 预测模型精度, 采用 MFO 优化 LSTM 算法学习率以及最大训练周期, 其中 l_{\max} 为最大迭代次数, n 为飞蛾数量, ub, lb 分别为待优化参数上下限, 蛾群的空间维度 d 即为待优化参数个数, 本文 $d=2$, 学习率及最大训练周期上下限为 $ub=[1, 300]$, $lb=[0, 0]$

3) 随机产生初始飞蛾种群 M , 可表示为式(13)。

$$M = \begin{bmatrix} m_{11} & \cdots & m_{1d} \\ \vdots & & \vdots \\ m_{n1} & \cdots & m_{nd} \end{bmatrix} \quad (13)$$

飞蛾适应度值作为优化函数返回值储存在列向量 OM 中, 其中第 i 只飞蛾对应的适应度值为 OM_i 。

4) 在 MFO 算法中, 每只飞蛾对应唯一的火焰, 飞蛾沿着对应火焰位置螺旋搜索, 这种方式使飞蛾能在全局勘探空间中进行充分的搜索, 避免陷入局部最优的情况, 增强寻优能力, 火焰维度与飞蛾维度相同, 因此随机初始化的火焰位置 F 表示为

$$F = \begin{bmatrix} F_{11} & \cdots & F_{1d} \\ \vdots & & \vdots \\ F_{n1} & \cdots & F_{nd} \end{bmatrix} \quad (14)$$

同理存储火焰适应度值至列向量 OF 。

5) 令迭代次数 $l=0$ 开始迭代, 更新种群并不断寻优, 直到达到最大迭代次数 l_{\max} , 飞蛾寻优过程可用螺旋函数 S 表示, 计算公式为

$$S(M_i, F_j) = D_i \cdot e^{bt} \cdot \cos(2\pi t) + F_j \quad (15)$$

$$D_i = |F_j - M_i| \quad (16)$$

式中: M_i 为第 i 只飞蛾; F_j 为第 j 个火焰; D_i 为第 i 只飞蛾到第 j 个火焰的距离; b 为对数螺旋线形状常数; t 取值范围为 $[-1, 1]$, t 取 -1 时离火焰最近, 取 1 时离火焰最远。

6) 将整个迭代过程中表现最优的飞蛾对应的适应度值, 即待优化参数最优值返回给 LSTM 神经网络进行负荷预测任务。

MFO 优化 LSTM 算法流程如图 5 所示。

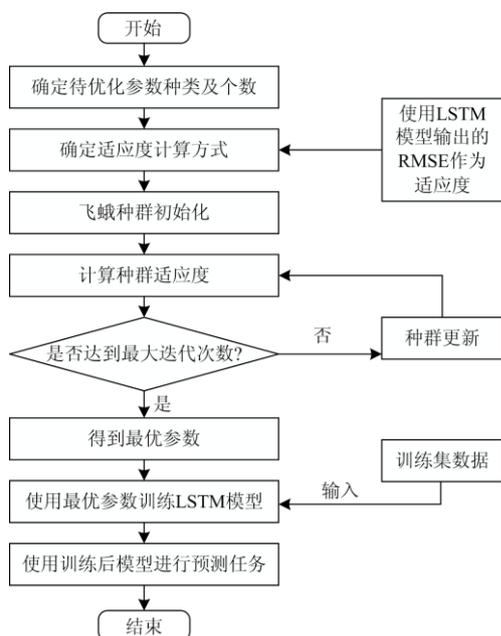


图 5 MFO 优化 LSTM 算法流程图

Fig. 5 Flow chart of MFO optimized LSTM algorithm

3 算例仿真

3.1 实验评价指标

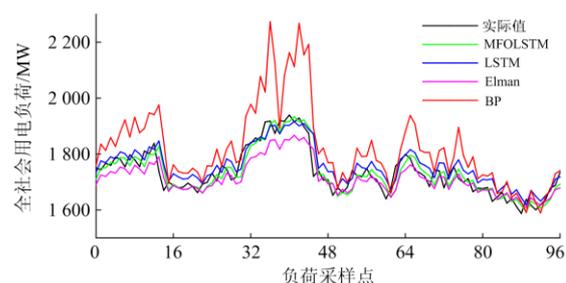
根据机器学习回归问题常用的评价指标以及相关文献^[23], 本文选取均方根误差(RMSE)、平均绝对百分比误差(MAPE)以及运行时间作为电力负荷预测好坏程度评价指标。

3.2 MFO 算法改进 LSTM 对比实验

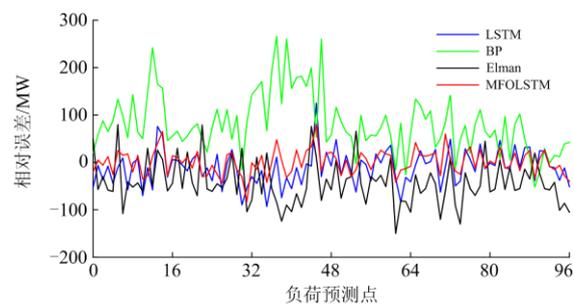
本节对某地区日负荷实验数据进行多步预测, 将影响负荷变化的 6 种气象数据根据第 1.2 节所述的改进 AprioriTid 算法进行降维处理, 得到三维气象序列, 并引入人体舒适度评价指标进一步降维得到一维气象序列, 协同电力负荷数据分别输入到 Elman 神经网络模型、BP 神经网络模型、LSTM 神经网络模型、MFOLSTM 神经网络模型进行对比实验。实验数据选取该地区 2019 年 1 月 1 日至 3 月 31 日某省供负荷数据以及实时气象数据, 15 min 进行一次采样, 一天 24 h 共 96 组采样点。此次实验取前 80 天共 7 680 组降维气象以及负荷数据作为训练集, 后 10 天共 960 组降维气象以及负荷数据作为测试集, 通过对前 80 天电力负荷数据以及气象数据进行数学建模, 预测未来 10 天电力负荷, 经过降维处理此时各神经网络模型输入层节点数降为 2, 输出层节点数为 1, 考虑隐含层层数过深可能导致过拟合, 使模型难以收敛的问题, 因此本实验设置隐含层层数为 2, 节点数分别为 50、100, 在 MFOLSTM 模型当中使用 LSTM 模型评价指标均方根误差作为

适应度函数返回值, 设定 MFO 算法中飞蛾数量为 30, 最大迭代次数为 50, 待优化参数个数为 2, 取值范围与第 2.3 节相同, 最终得到优化后的学习率以及训练次数分别为 0.024, 189。实验结果取各模型预测测试集中 2019 年 3 月 31 日一天 96 个负荷采样点曲线进行对比分析。

由图 6(a)各模型预测效果可以看出, 相较于 BP 以及 Elman 神经网络, LSTM 神经网络预测结果与负荷的真实情况更为接近, 而采用 MFO 优化后的 LSTM 模型进一步减小了与实际值的偏差, 使预测结果更加精准, 采用上述几种网络模型进行负荷预测, 评价指标数据见表 3。



(a) 不同模型预测结果对比



(b) 不同模型相对误差曲线

图 6 日负荷预测结果对比

Fig. 6 Comparison of daily load forecasting results

表 3 不同模型预测结果评价指标

Table 3 Evaluation index of prediction results of different models

模型	RMSE/MW	MAPE/%	运行时间/s
BP 神经网络	103.53	6.10	232
Elman 神经网络	55.87	3.29	208
LSTM 神经网络	37.90	2.18	142
MFOLSTM 神经网络	23.82	1.36	153

可见, 相较于其他 3 种方法, 本文提出的 MFOLSTM 拥有更高的精度, 虽比原始 LSTM 多需 11 s 运行时长, 但相较于 BP 神经网络与 Elman 神经网络运算速度分别快了 79 s 和 55 s。在负荷的峰谷附近, 一般会因为负荷变化的不确定性导致预测结果并不理想, 可能产生极端情况, 但本文所提

MFOLSTM 模型误差变化较为平缓, 保持在一个比较低的水平, 能够更好地拟合出负荷变化趋势曲线。说明改进 MFOLSTM 神经网络模型在处理时序信息时拥有更好的鲁棒性与稳定性, 更适合应用到短期负荷预测当中, 图 6(b)则为采用不同神经网络进行预测时的相对误差值。

4 结论

为提高负荷预测的可靠性, 降低预测误差, 本文从影响负荷预测的两大要素即数据样本和预测模型入手进行研究, 针对地区电网气象数据的复杂性, 提出改进 AprioriTid 关联规则分析算法, 降低气象数据维度, 很好地改善数据拥挤问题, 并在此基础上尽可能保留影响程度较高数据类型。

提出 MFO 优化的 LSTM 神经网络算法, 在算法优化上通过与 PSO 优化算法、BA 优化算法进行对比分析, 验证了 MFO 优化算法拥有更好的寻优能力以及寻优速度, 能够很好地避免寻优过程陷入局部最小; 在模型预测上通过与 BP 神经网络、Elman 神经网络、LSTM 神经网络进行对比, 实验结果表明 MFO 改善了 LSTM 神经网络训练周期以及学习率, 与其他 3 种算法对比拥有更好的网络预测精度。

通过对比实验结果可以清晰看出本文所提 AprioriTid-MFOLSTM 方法降低了数据样本维度, 简化了网络输入, 提高了负荷预测精准度, 为电网安全可靠运行提供了理论依据。随着大数据信息时代的发展, 负荷预测研究将向着更加精细化的方向发展, 未来可与边缘计算技术进行结合, 进一步对供电区域进行细致划分, 充分发挥大数据时代信息交互优势以及边缘计算技术信息处理优势, 以提高电力负荷预测精确度与实时性。

参考文献

- [1] 肖白, 周潮, 穆钢. 空间电力负荷预测方法综述与展望[J]. 中国电机工程学报, 2013, 33(25): 78-92.
XIAO Bai, ZHOU Chao, MU Gang. Review and prospect of spatial power load forecasting methods[J]. Proceedings of the CSEE, 2013, 33(25): 78-92.
- [2] 廖旋焕, 胡智宏, 马莹莹, 等. 电力系统短期负荷预测方法综述[J]. 电力系统保护与控制, 2011, 39(1): 147-152.
LIAO Nihuan, HU Zhihong, MA Yingying, et al. Review of the short-term load forecasting methods of electric power system[J]. Power System Protection and Control, 2011, 39(1): 147-152.
- [3] ÜRGE-VORSATZ D, CABEZA L F, SERRANO S, et al. Heating and cooling energy trends and drivers in buildings[J]. Renewable and Sustainable Energy Reviews, 2015, 41: 85-98.
- [4] 王继业, 季知祥, 史梦洁, 等. 智能配用电大数据需求分析与应用研究[J]. 中国电机工程学报, 2015, 35(8): 1829-1836.
WANG Jiye, JI Zhixiang, SHI Mengjie, et al. Demand analysis and application research of smart distribution power big data[J]. Proceedings of the CSEE, 2015, 35(8): 1829-1836.
- [5] 汪付华, 周后福, 戴金源, 等. 基于经济气象因素的月用电负荷预测模型研究[J]. 电力需求侧管理, 2020, 22(5): 78-82.
WANG Fuhua, ZHOU Houfu, DAI Jinyuan, et al. Research on monthly power load forecasting model based on economic and meteorological factors[J]. Power Demand Side Management, 2020, 22(5): 78-82.
- [6] 席雅雯, 吴俊勇, 石琛, 等. 融合历史数据和实时影响因素的精细化负荷预测[J]. 电力系统保护与控制, 2019, 47(1): 80-87.
XI Yawen, WU Junyong, SHI Chen, et al. A refined load forecasting based on historical data and real-time influencing factors[J]. Power System Protection and Control, 2019, 47(1): 80-87.
- [7] FOUCQUIER A, ROBERT S, SUARD F, et al. State of the art in building modelling and energy performances prediction: a review[J]. Renewable & Sustainable Energy Reviews, 2013, 23: 272-288.
- [8] 李焱, 贾雅君, 李磊, 等. 基于随机森林算法的短期负荷预测[J]. 电力系统保护与控制, 2020, 48(21): 117-124.
LI Yan, JIA Yajun, LI Lei, et al. Short term power load forecasting based on a stochastic forest algorithm[J]. Power System Protection and Control, 2020, 48(21): 117-124.
- [9] 刘建华, 李锦程, 杨龙月, 等. 基于 EMD-SLSTM 的家庭短期负荷预测[J]. 电力系统保护与控制, 2019, 47(6): 40-47.
LIU Jianhua, LI Jincheng, YANG Longyue, et al. Short-term household load forecasting based on EMD-SLSTM[J]. Power System Protection and Control, 2019, 47(6): 40-47.
- [10] 张素香, 赵丙镇, 王风雨, 等. 海量数据下的电力负荷短期预测[J]. 中国电机工程学报, 2015, 35(1): 37-42.
ZHANG Suxiang, ZHAO Bingzhen, WANG Fengyu, et al. Short-term load forecasting based on massive data[J]. Proceedings of the CSEE, 2015, 35(1): 37-42.
- [11] BESSANI M, MASSIGNAN J A D, SANTOS T M O, et al. Multiple households very short-term load forecasting

- using Bayesian networks[J]. *Electric Power Systems Research*, 2020, 189.
- [12] SALKUTI S R. Short-term electrical load forecasting using radial basis function neural networks considering weather factors[J]. *Electrical Engineering*, 2018, 100: 1985-1995.
- [13] CHITALIA G, PIPATTANASOMPORN M, GARG V, et al. Robust short-term electrical load forecasting framework for commercial buildings using deep recurrent neural networks[J]. *Applied Energy*, 2020, 278.
- [14] 潘晓杰, 张立伟, 张文朝, 等. 基于飞蛾扑火优化算法的多运行方式电力系统稳定器参数协调优化方法[J]. *电网技术*, 2020, 44(8): 3038-3046.
- PAN Xiaojie, ZHANG Liwei, ZHANG Wenchao, et al. Coordinated optimization method for parameters of power system stabilizer with multiple operation modes based on moth-flame optimization algorithm[J]. *Power System Technology*, 2020, 44(8): 3038-3046.
- [15] 方鑫, 殷俊, 蒋苏, 等. 基于等距 K-means 和 Apriori 算法的配电网故障规律挖掘方法[J]. *智慧电力*, 2020, 48(10): 99-104.
- FANG Xin, YIN Jun, JIANG Su, et al. Distribution network fault rule mining method based on equidistant K-means and Apriori algorithm[J]. *Smart Power*, 2020, 48(10): 99-104.
- [16] 钟倩漪, 钱谦, 伏云发, 等. 粒子群优化算法在关联规则挖掘中的研究综述[J]. *计算机科学与探索*, 2021, 15(5): 777-793.
- ZHONG Qianyi, QIAN Qian, FU Yunfa, et al. Review of particle swarm optimization algorithm in association rule mining[J]. *Journal of Frontiers of Computer Science and Technology*, 2021, 15(5): 777-793.
- [17] 邹浩, 窦震海, 张博, 等. 基于提升小波和改进 PSO-Elman 神经网络的短期负荷预测[J]. *电测与仪表*, 2020, 57(21): 119-125.
- ZOU Hao, DOU Zhenhai, ZHANG Bo, et al. Short-term load forecasting based on lifting wavelet and improved PSO-Elman neural network[J]. *Electrical Measurement & Instrumentation*, 2020, 57(21): 119-125.
- [18] BOZORG M, BRACALE A, CARAMIA P, et al. Bayesian bootstrap quantile regression for probabilistic photovoltaic power forecasting[J]. *Protection and Control of Modern Power Systems*, 2020, 5(3): 218-229. DOI: 10.1186/s41601-020-00167-7.
- [19] BENTO P M R, POMBO J A N, CALADO M R A, et al. Optimization of neural network with wavelet transform and improved data selection using bat algorithm for short-term load forecasting[J]. *Neurocomputing*, 2019, 358.
- [20] 仇媛, 常相茂, 仇倩, 等. 基于长短期记忆网络和滑动窗口的流数据异常检测方法[J]. *计算机应用*, 2020, 40(5): 1335-1339.
- QIU Yuan, CHANG Xiangmao, QIU Qian, et al. Anomaly detection method of stream data based on long short term memory network and sliding window[J]. *Journal of Computer Application*, 2020, 40(5): 1335-1339.
- [21] 杨弘, 田晶, 王可, 等. 混合型缺失数据填补方法比较与应用[J]. *中国卫生统计*, 2020, 37(3): 395-399.
- YANG Hong, TIAN Jing, WANG Ke, et al. Comparison and application of mixed missing data imputation methods[J]. *Chinese Journal of Health Statistics*, 2020, 37(3): 395-399.
- [22] 刘荣, 方鹏飞. 改进 Elman 神经网络的综合气象短期负荷预测[J]. *电力系统保护与控制*, 2012, 40(22): 113-117.
- LIU Rong, FANG Gefei. Integrated meteorological short-term load forecasting based on improved Elman neural network[J]. *Power System Protection and Control*, 2012, 40(22): 113-117.
- [23] 徐诗鸿, 张宏志, 林湘宁, 等. 基于改进评价指标的波动性负荷短期区间预测[J]. *电力系统自动化*, 2020, 44(2): 156-163.
- XU Shihong, ZHANG Hongzhi, LIN Xiangning, et al. Short-term interval forecasting of fluctuating load based on improved evaluation index[J]. *Automation of Electric Power Systems*, 2020, 44(2): 156-163.

收稿日期: 2021-01-08; 修回日期: 2021-04-27

作者简介:

王凌云(1981—), 男, 博士, 副教授, 硕士生导师, 主要研究方向为电力系统运行与控制; E-mail: wly@ctgu.edu.cn

林跃涵(1997—), 男, 通信作者, 硕士研究生, 主要研究方向为电力系统运行与控制; E-mail: 506207004@qq.com

童华敏(1980—), 男, 硕士, 高级工程师, 主要研究方向为电力系统运行与控制。E-mail: 6354073@qq.com

(编辑 葛艳娜)