

DOI: 10.19783/j.cnki.pspc.190632

基于即时学习算法的短期负荷预测方法

朱清智^{1,2}, 董泽², 马宁²

(1. 华北电力大学, 河北 保定 071003; 2. 河南工业职业技术学院, 河南 南阳 473000)

摘要: 针对电力系统短期负荷数据存在非线性和时变性等问题, 提出了一种变量相关性局部即时学习算法和最小二乘支持向量机(LSSVM)的电力系统短期负荷预测模型。利用互信息计算气象数据、各气象因素等变量的相关性, 并引入到即时学习算法训练集中, 用以选择当前电力系统负荷的建模邻域, 提高系统短期负荷模型预测的精度。利用相似度阈值对局部模型进行自适应更新, 增强系统负荷模型实时性。利用 Matlab 对某市宛城区的负荷量进行预测, 结果表明, 基于即时学习算法的电力系统短期负荷预测模型误差更小, 系统预测精度更高。

关键词: 短期电力负荷; 最小二乘支持向量机; 即时学习算法; 变量相关性; 相似度阈值

Forecasting of short-term power based on just-in-time learning

ZHU Qingzhi^{1,2}, DONG Ze², MA Ning²

(1. North China Electric Power University, Baoding 071003, China; 2. Henan Polytechnic Institute, Nanyang 473000, China)

Abstract: In view of the non-linearity and time-varying of short-term load data in power system, a local instant learning algorithm based on variable correlation and a short-term load forecasting model based on least squares support vector machine are proposed. Mutual information is used to calculate the correlation of meteorological data, meteorological factors and other variables, and it is introduced into the training set of real-time learning algorithm to select the current power system load modeling neighborhood and improve the accuracy of short-term load model prediction. Similarity threshold is used to update the local model adaptively to enhance the real-time performance of the system load model. The load forecasting in Wancheng District of a City is carried out by using Matlab. The results show that the short-term load forecasting model based on instant learning algorithm has smaller error and higher prediction accuracy.

This work is supported by National Natural Science Foundation of China (No. 71471060) and Scientific and Technological Project of Henan Province (No. 202102210134).

Key words: short-term load forecasting; LSSVM; JIT; variable correlation; similarity threshold

0 引言

电力负荷预测对电力系统内部发电机组运行控制的合理规划研究具有重要的意义, 也是保障电力安全运行的基础。同时可以进行合理规划机组检修计划, 科学管理和控制电力供应成本, 实现经济与社会效益最大化。随着计算机技术发展和人工智能算法的完善, 基于实时过程数据的建模方法得到研究与应用。文献[1]提出了利用 BP 与多项式拟合组合模型预测电力负荷, 在预测时剔除误差大的数据, 预测精度不是很高。文献[2]提出优化权值和阈值的

RBF 神经网络改进算法预测电力负荷, 相比传统 RBF 神经网络预测精度得到提高, 但是收敛速度、局部收敛等问题没有得到解决。文献[3]提出了卡尔曼滤波优化算法预测电力负荷, 相比卡尔曼滤波算法预测精度、收敛速度、稳定性等得到改善, 但是负荷在突变时预测精度较差。文献[4]提出了极限学习机优化算法预测电力负荷, 相比单一算法预测精度得到改善, 但是模型泛化能力不强。

在短期负荷电力系统中, 影响负荷的各种气象因素会随着时间发生变化, 利用单一固定模型预测电力负荷时, 预测误差随气象因素的变化而增大。因此, 建立电力负荷预测模型需要随气象因素的改变即时更新, 才可以精确反映短期电力负荷。现在, 电力系统将即时学习方法(JIT) 用于系统建模预测,

基金项目: 国家自然科学基金项目资助(71471060); 河南省科技攻关项目资助(202102210134)

从而提高模型的泛化性、实时性。文献[14]在石油动液面预测模型中采用基于相似度的局部即时学习更新策略, 预测结果得到很大改善。文献[15]提出基于权重平均法局部及时算法的电力短期负荷预测模型, 然而当前对于电力系统短期负荷预测研究多数集中于离线模型等方面, 模型预测的实时性不强。

在基于即时学习^[16]的建模方法中, 关键的环节是局部模型的建立, 而如何选取有效的学习集尤为重要。现有的即时学习算法学习集的选取多数是根据样本空间的欧氏距离的大小^[17], 而不考虑输入与输出数据的相关性, 且对于任何一个工作点都逐一建立局部模型, 因而需要大量计算时间。因此, 本文提出综合互信息和加权样本的相似性指数用于选取学习集, 即计算出每一个输入量与输出量之间的相关度, 然后将相关度转化为权重因子参与样本相似性计算, 使学习集的选择更加合理, 进而提高局部模型的准确性; 设置模型更新相似度阈值用以判断是否需要重新建立局部模型^[18]。最后, 采用数据集验证了所提算法的有效性, 并利用南阳市宛城区的负荷量运行数据进行了仿真试验, 取得了良好的预测效果。

1 基于即时学习算法的 LSSVM 模型

全局模型预测方法的训练样本需要大量历史数据, 而基于即时学习算法只选择与当前工作点输入数据相似性较大的历史数据作为建模样本建立一系列局部模型。即局部模型的建立个数与工作点的个数相对应。图 1 给出了离线全局模型与基于即时学习算法局部模型示意图。

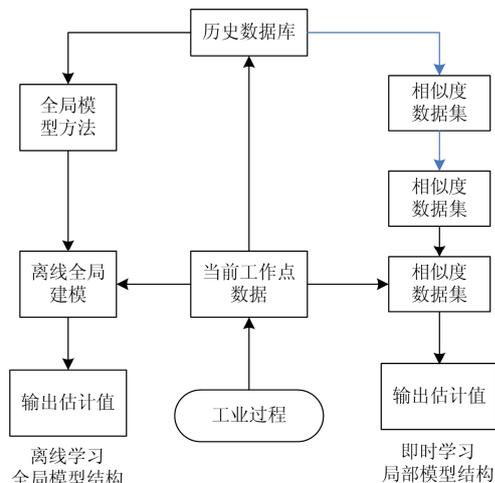


图 1 全局模型预测与局部模型预测关系

Fig. 1 Sketch map of global model and local model structure

即时学习算法与传统的数据驱动预测方法不同, 即时学习算法主要在于选取学习集, 依据相应的相似度准则, 从系统输入数据库中选取与当前工作点相似度大的数据点作为算法学习集, 进而对工作点进行输出预测。可见, 即时学习算法在不需建立全局模型条件下, 通过选取适当的训练样本(学习集)建立实时局部模型, 以满足电力系统短期负荷预测的需要。

设 $(\mathbf{X}_i, y_i), i=1, 2, \dots, N$ 为历史数据库中输入输出量, 其中 $\mathbf{X}_i=(x_{i1}, x_{i2}, \dots, x_{im})$ 为具有 m 个变量的输入向量, y_i 为输出值。对于当前工作点 \mathbf{X}_q , 计算其与历史数据库中输入向量 \mathbf{X}_i 的欧氏距离与夹角, 如式(1)所示。当前工作点 \mathbf{X}_q 与历史数据的相似度由式(2)计算得到。

$$\begin{cases} d(\mathbf{X}_i, \mathbf{X}_q) = \sqrt{\|\mathbf{X}_i - \mathbf{X}_q\|^2} \\ \theta(\mathbf{X}_i, \mathbf{X}_q) = \arccos\left(\frac{\mathbf{X}_i^T \mathbf{X}_q}{\|\mathbf{X}_i\|^2 \cdot \|\mathbf{X}_q\|^2}\right) \end{cases} \quad (1)$$

$$S(\mathbf{X}_i, \mathbf{X}_q) = \alpha e^{-d(\mathbf{X}_i, \mathbf{X}_q)} + (1 - \alpha) \cos[\theta(\mathbf{X}_i, \mathbf{X}_q)] \quad (2)$$

式中, α 为取值0至1的加权系数。

相似度 $S(\mathbf{X}_i, \mathbf{X}_q)$ 直接反映了 \mathbf{X}_i 与 \mathbf{X}_q 的相近程度。选取与当前工作点相似度最大的 k 个历史数据构造算法学习集, 即

$$\begin{cases} \{(X_1, y_1), (X_2, y_2), \dots, (X_k, y_k)\} \\ S(X_1, \mathbf{X}_q) > S(X_2, \mathbf{X}_q) > \dots > S(X_k, \mathbf{X}_q) \end{cases} \quad (3)$$

通过式(4)可以将即时学习的局部建模问题转化为优化问题。

$$J(\delta) = \min \sum_{i=1}^k |y - \hat{y}(\delta, \mathbf{X}_i)| S(\mathbf{X}_i, \mathbf{X}_q) \quad (4)$$

极小化目标函数 $J(\delta)$ 求得当前工作点的模型参数 δ , 可得到当前工作点的局部模型 $y_q = \hat{y}(\delta, \mathbf{X}_q)$ 。

最小二乘支持向量机(LSSVM)具有学习速度快, 可以实现少量数据集建模, 在给定的数据集, LSSVM将非线性数据集映射到高维空间, 使非线性问题转化为线性问题。基于即时学习算法的LSSVM将从历史数据库中寻找与当前预测点较大相似度的数据集映射到线性高维空间, 利用LSSVM将即时学习算法所选学习集映射到高维线性特征空间, 构建局部回归函数, 如式(5)所示。

$$y = \sum_{i=1}^k a_i k(\mathbf{X}_q, \mathbf{X}_i) + b \quad (5)$$

式中: a_i 、 b 分别表示拉格朗日算子和偏差值; \mathbf{X}_q 和

X_i 分别为工作点输入向量与算法学习集输入向量。

$k(X_q, X_i)$ 为高斯径向基核函数如式(6)所示。

$$k(X_q, X_i) = \exp(-\|X_q - X_i\|^2 / 2\sigma^2) \quad (6)$$

2 自适应即时学习算法

2.1 相似性指标

在电力系统运行过程中,系统输入变量与输出量往往具有不同的相关程度,因此在选取学习集时有必要考虑各个输入变量与输出量的相关性。本文利用互信息方法计算输入输出数据之间相关度,将其引入到数据相似度指标的计算中,进而可获取更为合理的学习集,提高局部模型的准确性。

对于输入向量 $X_i = (x_{i1}, x_{i2}, \dots, x_{im})$, $i = 1, 2, \dots, N$, 计算各气象数据变量与系统输出向量间的互信息如式(7)所示。

$$MI(x_d, y) = \phi(K) - \frac{1}{N} \sum_{i=1}^N (\phi(n_{x_{id}} + 1) + \phi(n_{y_i} + 1)) + \phi(N) \quad (7)$$

式中: $d = (1, 2, \dots, m)$; N 为数据的个数。将电力系统输入值与输出值组合在一起即 $Z = (x_d, y)$ 的2维向量,计算数据集其他点与 $z_i = (x_{id}, y_i)$ 点的欧氏距离并进行升序排列, digamma函数为 $\phi(\cdot)$, 其性质如式(8)所示。

$$\phi(n+1) = \phi(n) + \frac{1}{n} \quad (8)$$

式中, $\phi(1) = -0.5772516$ 。

根据每一个输入与输出变量相关度决定各变量的权重。 w_d 为第 d 个输入变量的权重,计算公式如式(9)所示。

$$w_d = \frac{MI(x_d, y)}{\sum_{d=1}^m MI(x_d, y)} \quad d = 1, \dots, m \quad (9)$$

$W = [w_1, \dots, w_m]^T$ 为输入权重向量,将权重值融入所需的历史数据和当前工作点,令 $X_i^w = X_i \text{diag}(W)$, ($i = 1, \dots, N$), $X_q^w = X_q \text{diag}(W)$, $\text{diag}(W)$ 为 W 的对角矩阵,则基于数据相关性的相似度准则如式(10)所示。

$$S(X_i^w, X_q^w) = (1 - \alpha) \cos[\theta(X_i^w, X_q^w)] + \alpha e^{-d(X_i^w, X_q^w)} \quad (10)$$

2.2 自适应局部模型更新策略

为应对电力系统工况和气象数据的变化,基于即时学习算法局部预测模型需要进行不断更新,但是将系统输入数据全部都建立局部预测模型需要进行大量的计算,从而会影响预测模型的实时性。在

此,提出设定一个相似度阈值比较条件来判断是否建立局部预测模型,从而避免过度重构。即大于相似度阈值说明系统稳定,此时不要重构局部预测模型,并采用投影计算方法输出当前估计值。其具体过程如下。

设 X_t 为 t 时刻工作点数值, S^* 为其对应的相似度阈值, $S(X_t, X_{t-1})$ 为上时刻数据 X_{t-1} 的相似度值,若 $S(X_t, X_{t-1}) > S^*$, 则局部预测模型不更新, $S^* = S(X_t, X_{t-1})$, 电力负荷预测输出值由式(11)计算求得。

$$y_t = y_{t-1} + \frac{S(X_t, X_{t-1})}{S^*} \cdot (M - y_{t-1}) \quad (11)$$

式中, M 为样本数据集平均值。

若 $S(X_t, X_{t-1}) < S^*$, 则局部预测模型更新,更新值由式(11)求得,这时数据集的选取为工况点最大相似度的数据,依据选取数据更新局部预测模型。

如果 $S(X_t, X_{t-1}) < S^*$, 则需依据式(10),选择与当前工况点相似度最大的 k 组数据(k 为学习集大小,视生产过程而定)重新学习集,重新建立局部模型。

2.3 基于变量相关性自适应即时学习算法

基于即时学习算法的建模策略解决了搜索全局泛化误差最小模型难题,增加了建模的实时性,然而常规选择学习集的方法没有考虑到输入输出变量的相关性,忽视了主导影响因素,本文根据统计学中的互信息原理计算各变量与输出量的相关程度,使学习集的选取更加合理,进而提高了模型的精确度;引入相似度阈值,判断当前工作点是否需要重新建模,需要建模时,采用LSSVM建模方法更新局部模型,降低计算量^[19]。

基于变量相关性自适应即时学习算法的建模步骤如下。

步骤1 由式(7)计算各个输入变量与输出量的相关度,由式(9)计算每个变量的权重,将权重乘以相应的历史数据。

步骤2 将式(9)的计算结果乘以将当前工作点输入变量,再由式(10)计算得到当前工作点与上一时刻工作点的相似度 $S(X_t, X_{t-1})$ 。通过比较 $S(X_t, X_{t-1})$ 与模型更新阈值 S^* 的大小判断模型是否需要更新;

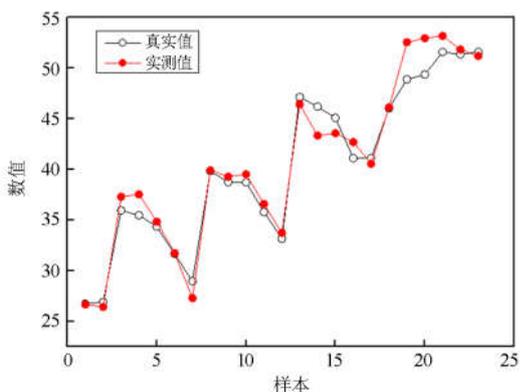
步骤3 若 $S(X_t, X_{t-1}) > S^*$, 说明当前工作点与上一时刻工作点工况非常接近,所以不需要更新局部模型,按式(11)计算当前工作点的输出值;反之,表明当前工作点与上一时刻工况相差较大,模型需要更新,按式(1)计算当前工作点与历史数据的距离和夹角余弦值,若余弦值小于0,则舍弃此历史数据,根据式(10)的选取准则选择学习集,利用LSSVM建模方法建立局部模型。

步骤4 读取下一时刻工作点。

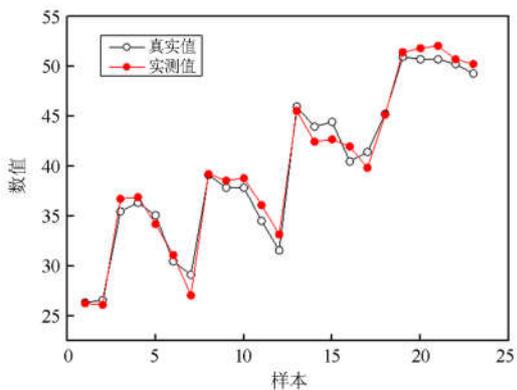
2.4 基于数据集的仿真验证

为了测试改进即时学习算法函数逼近和全局泛化能力, 采用标准回归数据集Slump进行仿真测试, 该数据集由103组数据组成, 每组数据含有1个因变量和7个自变量。Slump数据集作为标准测试集已经被广泛应用于建模方法验证^[19]。此次测试将113组观测数据中的前90组数据作为训练样本, 其余23组数据作为测试样本用来验证模型的性能。分别采用LSSVM全局模型、传统即时学习LSSVM模型(JIT-LSSVM)和本文提出的基于变量相关性自适应即时学习LSSVM模型(MI-SJIT-LSSVM)进行仿真测试。即时学习算法中相似度准则的加权系数 α 为0.56, 最小二乘支持向量机建模过程中的参数由交叉验证方法确定, 对测试样本的预测结果如图2所示。

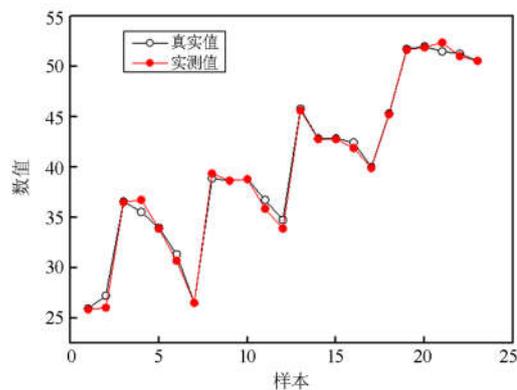
从图2可以看出, 基于变量相关性自适应即时学习算法所建模型的预测结果与真实数据拟合效果更好, 表明改进的即时学习算法具有更高的预测精度。为了更准确评估改进模型性能, 使用均方根误差(ξ_{RMSE})、平均绝对百分比误差(ξ_{MAPE})和最大相对误差(ξ_{MRE})进行评价, 计算公式如式(12)所示。



(a) LSSVM 模型预测结果



(b) 基于 JIT 预测结果



(c) 基于改进的 JIT 预测结果

图2 三种不同模型预测结果

Fig. 2 Prediction results of 3 kinds of different models

$$\begin{cases} \xi_{RMSE} = \sqrt{[\sum_{i=1}^n (y_i - y'_i)^2] / n} \\ \xi_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y'_i}{y_i} \right| \\ \xi_{MRE} = \max\left(\frac{|y_i - y'_i|}{y_i}\right) \end{cases} \quad (12)$$

式中: y_i 、 y'_i 分别表示实际输出值与预测输出值; n 代表测试样本个数。表1给出了三种模型预测误差对比结果, 基于变量相关性自适应即时学习算法的均方根误差、平均绝对百分比误差和最大相对误差分别为0.581 0、1.00%和5.26%, 三项误差指标均小于传统即时学习算法和LSSVM全局模型, 验证了基于改进的即时学习建模算法的有效性, 也表明基于变量相关性自适应即时学习算法具有更强的适应性和泛化能力。

表1 不同模型测试误差仿真结果

Table 1 Simulation results of four modeling methods

| 方法 | ξ_{RMSE} / MPa | $\xi_{MAPE} / \%$ | ξ_{MRE} |
|---------------|---------------------------|-------------------|-------------|
| LSSVM | 1.384 3 | 2.50 | 6.84 |
| JIT-LSSVM | 1.049 2 | 2.39 | 6.52 |
| MI-SJIT-LSSVM | 0.581 0 | 1.00 | 5.26 |

3 电力负荷预测模型与测试

根据文献[21]可知, 日最大负荷、最小负荷、平均负荷和温度、湿度、降雨量、风力等气象数据间存在一定的相关度, 因此对电力负荷预测需要采用大样本数据进行建模。本文选择温度、湿度、降雨量、风力、气压等因素作为系统的输入, 电力负荷预测值作为系统的输出。系统函数如式(11)所示。局部模型样本输入向量为 $\mathbf{X}(t)=[X_1, X_2, X_3, X_4, X_5]^T$,

模型输出为 C_{out} 。

建立基于即时学习算法的电力负荷预测模型并进行验证，并与其他预测模型算法进行对比。测试数据来自南阳市宛城区的电力负荷量，采样周期为1 min。改进即时学习算法需要计算各个输入量与输出量之间的相关性，按式(6)计算输入信息与输出之间的互信息，其数值如表2所示。

表 2 系统输入输出量间的互信息

Table 2 Mutual information values between input and output variables

| 变量编号(d) | 变量名称 | $MI(x_d, y)$ |
|-------------|------|--------------|
| 1 | 温度 | 1.364 7 |
| 2 | 湿度 | 0.900 1 |
| 3 | 降雨量 | 0.710 1 |
| 4 | 风力 | 0.289 5 |
| 5 | 气压 | -0.274 9 |

LSSVM建模过程中的参数采用交叉验证方法确定。选取150组数据作为样本数据，50组数据作为测试样本，采用均方根误差(ξ_{RMSE})、平均绝对百分比误差(ξ_{MAPE})作为评价模型预测准确度标准。预测结果如图3所示。

从图 3 可看出，基于改进的即时学习算法模型预测值与实际值很相近，表明该模型预测精度比单一 LSSVM 模型、即时学习算法模型高。结果表明，基于改进的即时学习算法模型的预测效果满足实际工程要求。通过对比，可知单一 LSSVM 方法所建模型预测精度略高于传统即时学习算法，但是由于逐点建模和训练集较大，因而需要较大计算量；改进即时学习所建模型的预测精度明显优于前两种方法，并且所需时间最短，由此可见，改进即时学习建模方法通过分析输入输出数据之间的相关度，寻找到了更合适的建模样本，增强了模型的学习和泛化能力。

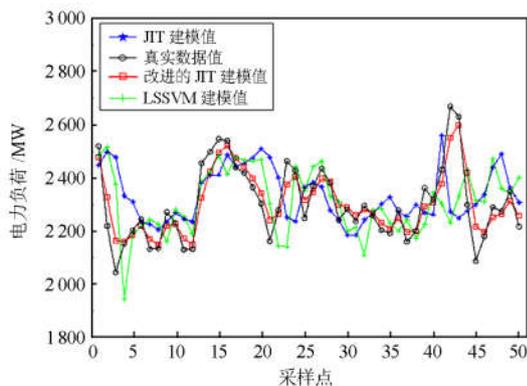


图 3 电力负荷预测结果

Fig. 3 Power load forecasting results

为了进一步测试改进后算法的性能，选取不同数量的测试样本进行仿真验证，分别选取300、600和900组数据作为数据样本，50组数据作为预测样本，测试结果如表3所示。由表3可知，随着样本数据的增加，LSSVM所需计算时间过大，不适合大样本建模；传统即时学习算法预测精度一直保持在10%左右，误差相对较大；改进后的即时学习算法则显示出较高的预测精度，且由于引入自适应更新策略，降低了局部模型更新频率，很大程度减小了计算量，进而缩短了建模时间。

综上所述，基于变量相关性的自适应即时学习算法在保证预测精度的同时提高了建模的实时性，可用于电力系统短期负荷预测模型。

表 3 不同数量测试样本仿真结果

Table 3 Simulation results of different number of test samples

| 样本数 | 方法 | $\xi_{RMSE} /(\text{kW/h})$ | $\xi_{MAPE} /\%$ | 时间/s |
|-----|--------------|-----------------------------|------------------|-------|
| 300 | LSSVM | 0.93 | 9.24 | 200.7 |
| | original JIT | 1.22 | 10.52 | 50.78 |
| | Improved JIT | 0.35 | 5.17 | 8.29 |
| 600 | LSSVM | 4.64 | 11.52 | 1032 |
| | original JIT | 4.42 | 10.10 | 79.30 |
| | Improved JIT | 1.53 | 5.04 | 16.84 |
| 900 | LSSVM | 8.91 | 24.71 | 6320 |
| | original JIT | 2.04 | 9.78 | 92.55 |
| | improved JIT | 0.73 | 4.32 | 20.25 |

4 结论

为了建立精确的电力系统负荷预测模型，提出了一种变量相关性局部即时学习算法和最小二乘支持向量机(LSSVM)的电力系统短期负荷预测模型。利用互信息计算气象数据、各气象因素等变量的相关度，并引入到即时学习算法训练集中，用以选择当前电力系统负荷的建模邻域，提高系统短期负荷模型预测的精度；利用相似度阈值对局部模型进行自适应更新，增强系统负荷模型实时性。电力负荷预测模型仿真实验结果表明，基于改进即时学习算法比基本算法具有更好的性能，为电力负荷预测提供了一种有效途径。

参考文献

[1] 张淑清, 任爽, 陈荣飞, 等. 基于大数据简约及 PCA 改进 RBF 网络的短期电力负荷预测[J]. 计量学报, 2018, 39(3): 392-397.

ZHANG Shuqing, REN Shuang, CHEN Rongfei, et al. Short-term power load forecast based on big data

- reduction and PCA-improved RBF network[J]. *Acta Metrologica Sinica*, 2018, 39(3): 392-397.
- [2] 金鑫, 李龙威, 季佳男, 等. 基于大数据和优化神经网络短期电力负荷预测[J]. *通信学报*, 2016, 37(增刊 1): 36-73.
JIN Xin, LI Longwei, JI Jianan, et al. Power short-term load forecasting based on big data and optimization neural network[J]. *Journal on Communications*, 2016, 37(S1): 36-73.
- [3] 王亚琴, 王耀力, 王力波, 等. 一种改进果蝇算法优化神经网络短期负荷预测模型[J]. *电测与仪表*, 2018, 55(22): 13-20.
WANG Yaqin, WANG Yaoli, WANG Libo, et al. An improved fruit fly optimization algorithm to optimize neural network short term load forecasting model[J]. *Electrical Measurement & Instrumentation*, 2018, 55(22): 13-20.
- [4] 林芳, 林焱, 吕宪龙, 等. 基于均衡 KNN 算法的电力负荷短期并行预测[J]. *中国电力*, 2018, 52(10): 88-96.
LIN Fang, LIN Yan, LÜ Xianlong, et al. Short-term parallel power load forecasting based on balanced KNN[J]. *Electric Power*, 2018, 52(10): 88-96.
- [5] 律方成, 刘怡, 亓彦珣, 等. 基于改进遗传算法优化极限学习机的短期电力负荷预测[J]. *华北电力大学学报*, 2018, 46(6): 1-7.
LÜ Fangcheng, LIU Yi, QI Yanxun, et al. Short-term load forecasting based on optimized learning machine using improved genetic algorithm[J]. *North China Electric Power University*, 2018, 46(6): 1-7.
- [6] 李若晨, 朱帆, 朱永利, 等. 结合受限玻尔兹曼机的递归神经网络电力系统短期负荷预测[J]. *电力系统保护与控制*, 2018, 46(17): 83-89.
LI Ruochen, ZHU Fan, ZHU Yongli, et al. Short-term power load forecasting using recurrent neural network with restricted Boltzmann machine[J]. *Power System Protection and Control*, 2018, 46(17): 83-89.
- [7] 吴云, 雷建文, 鲍丽山, 等. 基于改进灰色关联分析与蝙蝠优化神经网络的短期负荷预测[J]. *电力系统自动化*, 2018, 42(20): 67-75.
WU Yun, LEI Jianwen, BAO Lishan, et al. Short term load forecasting based on improved grey relational analysis and neural network optimized by bat algorithm[J]. *Automation of Electric Power Systems*, 2018, 42(20): 67-75.
- [8] 吴润泽, 包正睿, 王文韬, 等. Hadoop 架构下基于模式匹配的短期电力负荷预测方法[J]. *电工技术学报*, 2018, 33(7): 1542-1549.
WU Runze, BAO Zhengrui, WANG Wentao, et al. Short-term power load forecasting method based on pattern matching in Hadoop framework[J]. *Transactions of China Electrotechnical Society*, 2018, 33(7): 1542-1549.
- [9] 何耀耀, 刘瑞, 撒奥洋, 等. 基于实时电价与支持向量分位数回归的短期电力负荷概率密度预测方法[J]. *中国电机工程学报*, 2017, 37(3): 768-776.
HE Yaoyao, LIU Rui, HAN Aoyang, et al. Short-term power load probability density forecasting method based on real time price and support vector quantile regression[J]. *Proceedings of the CSEE*, 2017, 37(3): 768-776.
- [10] 雷景生, 郝珈玮, 朱国康, 等. 基于“分层-汇集”模型的短期电力负荷预测[J]. *电力建设*, 2017, 38(1): 68-76.
LEI Jingsheng, HAO Jiawei, ZHU Guokang, et al. Short-term power load forecasting based on ‘layered-confluence’ model[J]. *Electric Power Construction*, 2017, 38(1): 68-76.
- [11] DU W L, GUAN Z Q, QIAN F. The time series soft-sensor modeling based on Adaboost LS-SVM[C] // *The 8th World Congress on Intelligent Control and Automation (WCICA)*, July 7-9, 2010, Jinan, China: 1491-1495.
- [12] 金樑. SVM 与神经网络的组合模型在短期电力负荷预测中的应用研究[D]. 长春: 吉林大学, 2018.
JIN Liang. Research on short-term power load forecasting based on combination model of SVM and neural network[D]. Changchun: Jilin University, 2018.
- [13] 周红标, 王乐, 卜峰, 等. 基于 PSO-WPESN 的短期电力负荷预测方法[J]. *电测与仪表*, 2017, 54(6): 113-120.
ZHOU Hongbiao, WANG Le, BU Feng, et al. Short-term power load forecasting method based on PSO-WPESN[J]. *Electrical Measurement & Instrumentation*, 2017, 54(6): 113-120.
- [14] 王通, 高宪文, 刘文芳. 基于改进即时学习算法的动液面软测量建模[J]. *东北大学学报: 自然科学版*, 2015, 36(7): 918-922.
WANG Tong, GAO Xianwen, LIU Wenfang. Modeling of hydrodynamic soft sensing based on improved instant learning algorithm[J]. *Journal of Northeast University: Natural Science Edition*, 2015, 36(7): 918-922.
- [15] 程津, 黎燕, 夏向阳, 等. 基于双组合预测的经济—电力负荷预测模型[J]. *电力科学与技术学报*, 2018, 33(3): 20-28.
CHENG Jin, LI Yan, XIA Xiangyang, et al. Economic-electricity conduction prediction model based on dual combination prediction[J]. *Journal of Electric Power Science and Technology*, 2018, 33(3): 20-28.
- [16] 谷云东, 马冬芬, 程红超, 等. 基于相似度改进梯度提升决策树的电力负荷预测[J]. *电力系统及其自动化*

- 报, 2018, 9(10): 1-7.
- GU Yundong, MA Dongfen, CHENG Hongchao, et al. Power load forecasting based on similar data selection and improved gradient boosting decision tree[J]. Proceedings of the CSU-EPSCA, 2018, 9(10): 1-7.
- [17] 张雨金, 杨凌帆, 葛双冶, 等. 基于Kmeans-SVM的短期光伏发电功率预测[J]. 电力系统保护与控制, 2018, 47(21): 118-124.
- ZHANG Yujin, YANG Lingfan, GE Shuangzhi, et al. Power prediction of short-term photovoltaic generation based on Kmeans-SVM[J]. Power System Protection and Control, 2018, 47(21): 118-124.
- [18] 孙海蓉, 谢碧霞, 田瑶, 等. 基于数据的 Sec RPSO-SVM 短期电力负荷预测[J]. 系统仿真学报, 2017, 29(8): 1542-1549.
- SUN Hairong, XIE Bixia, TIAN Yao, et al. Forecasting of short-term power load of Sec RPSO-SVM based on data-driven[J]. Journal of System Simulation, 2017, 29(8): 1542-1549.
- [19] 董泽, 马宁, 任林. 基于变量相关性自适应即时学习算法的火电厂 SCR 脱硝系统建模[J]. 华北电力大学学报, 2019, 46(2): 83-90.
- DONG Ze, MA Ning, REN Lin. Modeling SCR denitrification system of thermal power plant based on variable correlation adaptive instant learning algorithm[J]. Journal of North China Electric Power University, 2019, 46(2): 83-90.
- [20] 张亚丽, 胡伯轩, 李莎莎, 等. 基于相似日搜索的改进LMD与ESN相结合的短期电力负荷预测模型[J]. 郑州大学学报, 2017, 33(7): 121-128.
- ZHANG Yali, HU Boxuan, LI Shasha, et al. The short-term power load forecasting model of combining ILMD and ESN based on similar days searching[J]. Journal of Zhengzhou University, 2017, 33(7): 121-128.
- [21] 薛茜. 营口地区电力系统短期负荷预测研究[D]. 北京: 华北电力大学, 2018.
- XUE Qian. Research on short-term load forecasting in power system based on district of Yingkou[J]. Beijing: North China Electric Power University, 2018.
- [22] 李廷顺, 王伟, 刘泽三, 等. 考虑不确定区间的电力负荷 GELM-WNN 预测[J]. 计算机工程, 2019, 1(1): 1-9.
- LI Yanshun, WANG Wei, LIU Zesan, et al. GELM-WNN forecasting of power load considering uncertain interval[J]. Computer Engineering, 2019, 1(1): 1-9.
- [23] 薛雪, 石文星, 孙天, 等. 一种应用于智能电网的建筑电力负荷互动管理策略[J]. 电力自动化设备, 2018, 38(12): 101-107.
- XUE Xue, SHI Wenxing, SUN Tian, et al. Interactive building power load management strategy for smart grid[J]. Electric Power Automation Equipment, 2018, 38(12): 101-107.
- [24] 陈俊艺, 丁坚勇, 田世明, 等. 基于改进快速密度峰值算法的电力负荷曲线聚类分析[J]. 电力系统保护与控制, 2018, 46(20): 85-94.
- CHEN Junyi, DING Jianyong, TIAN Shiming, et al. An improved density peaks clustering algorithm for power load profiles clustering analysis[J]. Power System Protection and Control, 2018, 46(20): 85-94.
- [25] 李如意, 黄明山, 周东国, 等. 基于粒子群算法搜索的非侵入式电力负荷分解方法[J]. 电力系统保护与控制, 2016, 44(8): 30-37.
- LI Ruyi, HUANG Mingshan, ZHOU Dongguo, et al. Optimized nonintrusive load disaggregation method using particle swarm optimization algorithm[J]. Power System Protection and Control, 2016, 44(8): 30-37.

收稿日期: 2019-06-02; 修回日期: 2019-07-21

作者简介:

朱清智(1980—), 男, 通信作者, 硕士研究生, 副教授, 研究方向为智能控制理论及应用; E-mail: zqz921@163.com

董泽(1970—), 男, 博士, 教授, 博士生导师, 研究方向为系统建模理论与方法研究。E-mail: 33906224@163.com

(编辑 张爱琴)