【电子与信息科学 / Electronics and Information Science】

基于 AP 相似日选取与 FISOA-RBF 的短期负荷预测

于军琪, 王佳丽, 赵安军, 解云飞, 冉彤, 赵泽华

西安建筑科技大学建筑设备科学与工程学院, 陕西西安 710055

摘要: 为提高建筑电力负荷的预测精度, 在考虑天气信息和日期类型等影响因素的基础上, 提出基于吸引子传播(affinity propagation, AP)相似日选取和改进搜索者优化算法-径向基(fusion improvement seeker optimization algorithm-radial basis function, FISOA-RBF)神经网络的建筑用电短期负荷预测模型. 采用 AP 算法对短期电力负荷进行相似日选取, 以克服外界环境对建筑电力负荷预测精度的影响; 以 RBF 神经网络的网络参数为优化对象, 采用搜索者优化算法(seeker optimization algorithm, SOA)进行参数寻优, 并引入融合改进策略提高传统种群算法的寻优性能, 以进一步提高 RBF 神经网络的预测精度和学习速度; 根据 FISOA 算法优化后的 RBF 神经网络对相似日数据进行训练, 建立最优参数下的建筑短期电力负荷预测 AP-FISOA-RBF 模型. 在相同数据集和气候特征条件下, 与传统 RBF、PSO-RBF 和 SOA-RBF 预测模型相比, AP-FISOA-RBF 模型平均预测绝对百分比误差分别降低了 93.05%、83.60% 和 71.13%, 平均预测速度分别提高了 54.34%、39.25% 和 23.96%, 表明 AP-FISOA-RBF 模型在预测精度和预测速度上的表现更好.

关键词: 神经网络; 吸引子传播; 相似日选取; 搜索者优化算法; 径向基; 建筑用电; 短期负荷预测
中图分类号: TU852 **文献标志码:** A **doi:** 10.3724/SP.J.1249.2021.03315

Short-term load forecasting based on AP similar days and FISOA-RBF

YU Junqi, WANG Jiali, ZHAO Anjun, XIE Yunfei,
RAN Tong, and ZHAO Zehua

School of Building Services Science and Engineering, Xi'an University of Architecture and Technology,
Xi'an 710055, Shaanxi Province, P. R. China

Abstract: In order to improve the accuracy of electrical load forecasting for large public buildings, we propose a forecasting model for the short-term load of large public buildings based on affinity propagation (AP) similar days selection and the fusion improvement seeker optimization algorithm-radial basis function (FISOA-RBF) neural network by considering the weather information, date type and other influencing factors. In order to overcome the influence of external environment on the accuracy of building electrical load forecasting, AP algorithm is used to select similar days of short-term electrical load. The structural parameters of RBF neural network are optimized by FISOA which uses the fusion improvement theory to further improve the prediction accuracy and the learning speed of RBF neural network. Finally, the similar daily load data are used to train an optimized FISOA-RBF to predict the short-term electrical load of buildings. In order to validate the effectiveness of the proposed model, the exhaustive experiments are conducted in comparison with RBF, PSO-RBF and SOA-RBF methods. The experimental results

Received: 2020-07-27; **Accepted:** 2021-01-19

Foundation: Social Development Agency Project of Key R & D Program of Shaanxi Province (2017ZDL-SF-16-5); Project of Intelligent Building and Building Energy Conservation of Anhui Jianzhu University (Z20190383)

Corresponding author: Associate professor ZHAO Anjun. E-mail: zhao_anjun@163.com

Citation: YU Junqi, WANG Jiali, ZHAO Anjun, et al. Short-term load forecasting based on AP similar days and FISOA-RBF [J]. Journal of Shenzhen University Science and Engineering, 2021, 38(3): 315-323. (in Chinese)

indicate that the proposed model outperforms the other models: the mean absolute percentage error (MAPE) is reduced by 93.05%, 83.60% and 71.13%, and the average prediction speed is increased by 54.34%, 39.25% and 23.96%, and thus demonstrate that AP-FISOA-RBF model in prediction accuracy and speed of prediction performance is better than other three RBF-based methods.

Key words: computer neural network; affinity propagation (AP); similar day selection; seeker optimization algorithm; radial basis function; electricity consumption of buildings; short-term load forecasting

大型公共建筑能耗大约占建筑总能耗的 1/3, 近年来随着社会经济的发展, 该比例越来越大^[1], 这令大型公共建筑能耗逐渐成为研究焦点. 准确可靠的大型公共建筑用电短期负荷预测 (short-term load forecasting, STLF) 是建筑进行合理能源调度和节能优化运行的前提. 与长期预测相比, 时效性较高的 STLF 主要用于供配电的合理规划, 受温差和湿度等突变因素影响大, 属于动态非线性时间序列^[2].

近年来, 许多学者提出了如人工神经网络 (artificial neural network, ANN)、自回归 (auto regressive, AR)、支持向量回归 (support vector regression, SVR) 及灰色模型 (gray model, GM) 等预测模型^[2-6]. 然而, AR 模型根据平稳线性特征处理时间序列, 难以适应动态非线性的 STLF 时间序列; SVR 更适合小样本数据, 在面对大规模训练样本时, 收敛速度慢; GM 适用于单调变化的时间序列, 难以预测波动较大的时间序列^[7]. 针对逆传播 (back propagation, BP) 神经网络存在收敛速度慢、易陷入局部极小值的不足^[8], 径向基 (radial basis function, RBF) 神经网络因只有一个隐层所以具有收敛速度快的特点, 被广泛用于不同的实际需求中^[9-10]. 选取合适的网络参数是提高 RBF 性能的有效手段^[11]. 回立川等^[12]采用近邻传播算法获取 RBF 神经网络的中心矢量, 提高了网络的训练精度, 但算法收敛速度慢. 翟莹莹等^[13]通过改进 k -means++ 算法和方差度量法, 提出一种组合式的 RBF 参数优化方法, 但该方法仍存在过拟合的问题.

搜索者优化算法 (seeker optimization algorithm, SOA) 是一种基于人群的启发式搜索算法^[14], 其全局搜索能力比粒子群优化 (particle swarm optimization, PSO) 算法强, 且不易受局部极值的影响^[15]. 尽管有研究人员成功将 SOA 用于参数寻优和模型改进中^[16-17], 但收敛速度慢和搜索精度低的缺陷仍令寻优结果不理想^[18].

此外, 考虑到气象和时间等因素对建筑用电负荷的影响^[19], 进行相似日选取可提升负荷预测模型的性能. 吸引力传播 (affinity propagation, AP) 算

法通过在待聚类对象之间传递相似度进行聚类^[20], 与传统的 k -means 和模糊 c 均值聚类算法相比, AP 算法参数设定简单, 所有样本均参与竞争迭代, 与目标对象的主要特征匹配更精准^[7]. 因此, 本研究采用 AP 聚类算法分解样本空间, 以期更准确的满足天气及日期类型的需求.

为提高利用 RBF 神经网络对大型公共建筑短期用电负荷预测的精度和速度, 提出一种基于融合策略的改进人群搜索算法 (fusion improvement seeker optimization algorithm, FISOA), 通过对传统 SOA 算法引入自适应速度因子, 加快对 RBF 网络参数的寻优速度; 采用多人协同搜索策略提高寻优效率; 通过精英后代遗传策略降低解的随机性, 并利用 FISOA 优化 RBF 神经网络的中心、宽度和权值. 仿真实验结果显示, 本研究所提基于 AP 相似日选取与 FISOA-RBF 神经网络模型 (简称 AP-FISOA-RBF 模型), 能有效处理连续非线性动态规划问题, 在预测精度和运行速度上均表现良好.

1 AP 相似日理论

AP 作为一种无监督聚类算法, 能更快更优地处理大规模数据^[21]. AP 相似日理论的关键在于建立给定历史数据的相似性矩阵, 并根据聚类特征获取历史负荷样本数据的相似日聚类结果. 利用欧式距离定义任意两个样本 X_i 与 X_j 之间的相似度为

$$S(i, j) = -\|X_i - X_j\|^2 \quad (1)$$

则所有样品的相似度构成相似度矩阵 S .

AP 算法通过在待聚类样本数据之间不断迭代代表矩阵 R 和归属矩阵 A , 并逐渐收敛至聚类中心^[20], 每个聚类中心点即该类样本的代表. 第 t 次迭代时, 样本点 j 适合作为样本点 i 的聚类中心的代表度 $R_t(i, j)$ 为

$$\begin{cases} R_t(i, j) = S_t(i, j) - \max\{A_t(i, j') + S_t(i, j')\}, i \neq j \\ R_t(j, j) = S_t(j, j) - \max\{A_t(j, j') + S_t(j, j')\}, i = j \end{cases} \quad (2)$$

其中, $j' \neq j$, 表示除样本点 j 以外的其他样本点. 因

此, 加入阻尼调节后实际的代表度 $R_{\text{act}(t+1)}$ 为第 $t+1$ 次迭代与第 t 次迭代的加权和, 即

$$R_{\text{act}(t+1)} = (1 - \lambda) R_{t+1} + \lambda R_t \quad (3)$$

$A_i(i, j)$ 为第 t 次迭代时, 样本点 i 选择样本点 j 作为聚类中心的合适程度即归属度, 表达式为

$$\begin{cases} A_i(i, j) = \min\{0, R_t(j, j) + \sum_{i' \neq \{i, j\}} \max\{0, R_t(i', j)\}\}, & i \neq j \\ A_i(j, j) = \sum_{i \neq j} \max\{0, R_t(i, j)\}, & i = j \end{cases} \quad (4)$$

其中, $i' \neq i$, 表示除样本点 i 以外的其他样本点. 同样的, 加入阻尼调节后实际的归属度 $A_{\text{act}(t+1)}$ 的更新规则为

$$A_{\text{act}(t+1)} = (1 - \lambda) A_{t+1} + \lambda A_t \quad (5)$$

其中, i 为待聚类中心; λ 为阻尼因子, $\lambda \in (0, 1)$ 默认 $\lambda = 0.75$. 决策矩阵为所有样本点的归属度矩阵 A 与代表度矩阵 R 的和. λ 的引入可避免在迭代过程中产生数据振荡, 保证决策矩阵的稳定收敛. 当矩阵收敛时, 将决策矩阵中的对角线元素大于 0 的数据点作为聚类中心, 其余点按照决策矩阵中最大值所在位置依次分配到各个聚类中心^[20].

2 RBF 神经网络

RBF 神经网络作为 3 层反馈神经网络, 基本结构包含 n 个神经元节点的输入层, m 个节点的隐含层和 k 个节点的输出层^[12]. RBF 神经网络利用径向基函数作为单隐层空间的基, 能将输入矢量 $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$ 直接映射到隐层空间, 并经隐层快速完成与输出层的线性映射, 大大加快了 RBF 的学习速度并避免算法陷入局部最优, 提高了非线性拟合能力, 适用于具有复杂非线性特点的建筑用电负荷预测. 隐含层 H 的第 j 个节点径向基函数是一个高斯函数, 表达式为

$$h_j = \exp[-\|x_i - c_j\|/(2b_j^2)], \quad j = 1, 2, \dots, m \quad (6)$$

其中, x_i 为第 i 个输入样本; c_j 为第 j 个网络节点中心; b_j 为第 j 个网络节点的网络基宽. 网络输出 $\mathbf{Y} = [y_1, y_2, \dots, y_k]^T$ 中的第 k 个节点由隐层函数的线性加权和表示, 即

$$y_k = \sum_{j=1}^m h_j w_{jk}, \quad j = 1, 2, \dots, m \quad (7)$$

其中, w_{jk} 为第 j 个隐层节点到第 k 个输出节点的权值.

3 SOA 及其改进策略

3.1 SOA

SOA 通过模拟人的智能搜索行为, 寻求问题最

优解^[14]. 算法以搜索队列为种群, 根据智能群体的经验梯度和不确定推理行为, 确定搜索方向和步长, 进行适应度评价并完成位置更新, 逐步逼近问题的最优解, 实现问题的全局优化^[22].

3.1.1 搜索步长

采用线性隶属函数表示搜索步长模糊变量, 结合文献[22], 设在最佳位置有最大隶属度值 $u_{\max} = 0.9000$, 最差位置有最小隶属度 $u_{\min} = 0.0111$. 适应度函数值 i 的隶属度 u_i 和 j 维搜索空间适应度函数值 i 的隶属度 $u_{i,j}$ 分别为

$$u_i = u_{\max} - \frac{s - I_i}{s - I}(u_{\max} - u_{\min}), \quad i = 1, 2, \dots, s \quad (8)$$

$$u_{i,j} = \text{rand}(u_i, 1), \quad j = 1, 2, \dots, D \quad (9)$$

其中, s 为种群规模; I_i 为种群按适应度降序排列后的个体位置编号, $I = 1$; $\text{rand}()$ 为随机数产生函数; D 为问题维数.

由 $u_{i,j}$ 得到第 j 维空间的搜索步长为

$$\alpha_{i,j} = \delta_{i,j} \sqrt{-\ln u_{i,j}} \quad (10)$$

其中, $\delta_{i,j}$ 为高斯隶属度函数参数, $\delta_{i,j} = \beta |x_{\min} - x_{\max}|$; $x_{\min}$ 和 $x_{\max}$ 是同一种群中最小和最大函数值位置; 惯性权值 β 跟随迭代过程从 0.9 线性递减至 0.1, $\beta = (t_{\max} - t)/t_{\max}$; t 和 $t_{\max}$ 为当前及最大迭代次数. $\alpha_{i,j}$ 在每迭代中都不小于 0.

3.1.2 搜索方向

第 i 个搜寻个体的搜索方向 $\mathbf{d}_i(t)$ 由利己方向 $\mathbf{d}_{i,\text{ego}}$ 、利他方向 $\mathbf{d}_{i,\text{alt}}$ 和预动方向 $\mathbf{d}_{i,\text{pro}}$ 加权确定^[20], 即

$$\mathbf{d}_i(t) = \text{sign}(\beta \mathbf{d}_{i,\text{pro}} + \varphi_1 \mathbf{d}_{i,\text{ego}} + \varphi_2 \mathbf{d}_{i,\text{alt}}) \quad (11)$$

$$\mathbf{d}_{i,\text{ego}} = \mathbf{p}_{i,\text{best}} - \mathbf{x}_i(t) \quad (12)$$

$$\mathbf{d}_{i,\text{alt}} = \mathbf{g}_{i,\text{best}} - \mathbf{x}_i(t) \quad (13)$$

$$\mathbf{d}_{i,\text{pro}} = \mathbf{x}_i(t_1) - \mathbf{x}_i(t_2) \quad (14)$$

其中, $\text{sign}()$ 为符号函数; φ_1 和 φ_2 为 $[0, 1]$ 内的常数; $\mathbf{x}_i(t_1)$ 和 $\mathbf{x}_i(t_2)$ 分别为 $\{\mathbf{x}_i(t-2), \mathbf{x}_i(t-1), \mathbf{x}_i(t)\}$ 中的前 2 名最佳位置; $\mathbf{g}_{i,\text{best}}$ 为第 i 个搜寻个体所在种群的集体历史最佳位置; $\mathbf{p}_{i,\text{best}}$ 为第 i 个搜寻个体到目前为止经历过的最佳位置.

3.1.3 位置更新

根据搜索方向和步长可实现位置的更新为

$$\mathbf{x}_{i,j}(t+1) = \mathbf{x}_{i,j}(t) + \Delta \mathbf{x}_{i,j}(t+1) \quad (15)$$

其中, $\Delta \mathbf{x}_{i,j}(t+1) = \alpha_{i,j}(t) \mathbf{d}_{i,j}(t)$; $\mathbf{d}_{i,j}(t)$ 为第 j 维空间的第 i 个搜寻个体的搜索方向.

3.2 FISOA

3.2.1 自适应搜索改进

针对传统 SOA 收敛速度慢的问题, 本研究提出的 FISOA 在搜索过程中, 引入自适应搜索速度 v 及适应系数 η , 以实现速度自适应, 令 SOA 的迭代更新速度在数据量较大时, 也能保持在良好水平.

第 i 个搜寻个体在 j 维空间里的速度适应过程为

$$v_{i,j}(t+1) = \eta v_{i,j}(t) \quad (16)$$

$$\eta = \begin{cases} \beta_{\min} - \frac{(\beta_{\max} - \beta_{\min})(f - f_{\min})}{f_{\text{avg}} - f_{\min}}, & f \leq f_{\text{avg}} \\ \beta_{\max}, & f > f_{\text{avg}} \end{cases} \quad (17)$$

其中, t 为迭代次数; $\beta_{\min}$ 和 $\beta_{\max}$ 分别为惯性权重最小值和最大值; f 为当前位置的适应度; $f_{\min}$ 和 f_{avg} 分别为适应度最小值和平均值.

3.2.2 搜索模式改进

传统 SOA 的单队列搜索模式严重影响搜索的效率和成功率, 因此, 本研究模拟人类的合作行为, 提出一种多人协同搜索模式, 通过将全体划分为多个子群体, 使得在每一个子群体空间都能同时更新搜索步长、方向和速度, 并根据适应度条件判断是否完成搜索.

设 s 为群体规模, l 为每个子群体中的个体数, 则子目标群体数 $g = s/l$. 至此, 可建立 $g \times l$ 维的解空间矩阵 $X = (x_{ij})$. 其中, $i = 1, 2, \dots, g; j = 1, 2, \dots, l$.

3.2.3 精英杂交策略

为提高 SOA 解空间的质量, 本研究提出精英杂交遗传策略, 以期能在最少的迭代次数中寻求最优解, 令算法表现出更强的适应度, 也获得较高的收敛精度.

首先, 对局部最优解按照适应度由优至劣排序后记为 $P = [f_1, f_2, \dots, f_l]$, 取前 k 名组成“精英”, 记为 $K = [f_1, f_2, \dots, f_k]$, 个体间的差异系数为

$$\varepsilon = |f_{(i+1)} - f_i| \quad (18)$$

其中, $f_{(i+1)}$ 和 f_i 分别为两个不同个体的适应度.

在算法迭代过程中, 利用如式(19)的杂交因子 α , 将保留的“精英”在杂交池中杂交 g 代, 并用后代更替父代, 以保持种群数目不变.

$$\alpha = \begin{cases} \frac{|\varepsilon|}{f_{\text{best}}}, & \varepsilon > 0 \\ 1, & \varepsilon = 0 \end{cases} \quad (19)$$

其中, f_{best} 为最佳适应度值. 可见, 个体间的差异系数 ε 越大, 对精英后代的影响程度越大.

3.3 改进 SOA 算法性能测试

通过对传统 SOA 进行多策略融合改进, 提出了改进后的 FISOA 寻优算法, 具体步骤为:

- 1) 设定迭代次数初始值 $t = 0$.
- 2) 在可行解域随机产生 s 个初始位置.
- 3) 子群体分配. 将全体 s 划分为相互独立的 g 个子群体空间, 每个子群体中包含 l 个个体, 建立 $g \times l$ 维的子空间矩阵 X .
- 4) 在杂交池中按照式(18)和式(19)进行精英杂交并产生多组精英后代.
- 5) 计算每个搜索位置的适应度值.
- 6) 执行多人协同搜索策略, 在各个子空间内, 搜索者同时计算个体 i 在 j 维的搜索方向 $d_{i,j}(t)$ 及步长 $\alpha_{i,j}(t)$, 并根据自适应搜索速度 $v_{i,j}(t)$ 进行动态调整.
- 7) 判断终止条件. 当适应度或迭代次数达到设定值时跳出循环, 并输出寻优结果; 否则, 更新迭代次数并执行步骤 2).

采用 3 个典型测试函数 Sphere、Schaffer 和 Rastrigin (函数表达式及参数设置请扫描论文末页右下角二维码查看表 S1) 对算法进行验证. 记录 PSO、SOA 与 FISOA 算法对 3 个函数各运行 50 次后的平均最佳适应度值、平均收敛次数和达到最佳适应度的平均迭代次数, 如表 1, 适应度迭代过程如图 1 所示. 分析表 1 和图 1 可知, 多数情况下 FISOA 的性能比 PSO 和 SOA 算法表现更优, 收敛曲线更平滑, 收敛速度明显提高, 同时具有更好的全局搜索性能, 且适应度更强.

表 1 采用 PSO、SOA 与 FISOA 算法对 3 个函数的测试结果
Table 1 Test results of PSO, SOA and FISOA

测试函数	平均最佳适应度平均值			平均收敛次数			平均迭代次数		
	PSO	SOA	FISOA	PSO	SOA	FISOA	PSO	SOA	FISOA
Sphere	0.002 3	0.001 0	$1.618\ 5 \times 10^{-5}$	30	41	50	100	100	50
Schaffer	0.001 2	0.000 4	$1.907\ 2 \times 10^{-6}$	34	37	49	100	100	50
Rastrigin	0.001 3	0.000 8	$1.524\ 8 \times 10^{-5}$	29	31	50	200	200	60

图1 PSO、SOA 与 FISOA 算法在不同函数上的收敛性能

Fig. 1 (Color online) Algorithm convergence of PSO, SOA and FISOA

4 用电负荷预测模型

AP-FISOA-RBF 模型的用电负荷预测算法流程如图 2。首先,对天气信息、日期类型和历史负荷数据进行相关性分析,选取特征向量作为 AP 聚类的输入,获取 AP 聚类结果。然后,利用 AP 相似日理论,选取与预测日相关性较强的前 n 组 AP 聚类簇作为历史相似日,建立对应的 FISOA-RBF 神经网络相似日选取训练集并进行训练。最后,输出

图2 AP-FISOA-RBF 预测算法流程

Fig. 2 Flow chart of AP-FISOA-RBF forecasting algorithm

n 个第 i 簇相似日预测值 y_i 的加权求和结果 Y 作为最终实际预测值, 即

$$Y = \sum_{i=1}^n \varphi_i y_i \quad (20)$$

其中, φ_i 为预测权值, $\varphi_i = r_i / \sum r_i$; r_i 为相关系数。

在算法迭代的过程中,以 RBF 神经网络的中心 C 、宽度 B 和权值 W 建立初始搜索种群 $x = [c_1 \ b_1 \ w_1 \ c_2 \ b_2 \ w_2 \ \dots \ c_m \ b_m \ w_m]$, 寻求最小适应度下的最优解作为网络参数。以误差函数最小建立的适应度函数为

$$f_{\min} = \frac{1}{n} \sum_{i=1}^n \frac{|X_i(t) - R_i(t)|}{R_i(t)} \times 100\% \quad (21)$$

其中, $X_i(t)$ 和 $R_i(t)$ 分别为第 i 次数据采集得到的电力负荷的预测值和实际值; n 为预测时刻个数。

分析 FISOA-RBF 模型的适应度变化曲线 (请描述论文末页右下角二维码查看图 S1) 可知,融合策略的引入,保持了随机解的稳定性,能够更快更准确地寻求 RBF 参数的全局最优解,使得 RBF 获得更好的学习速度和精度。

5 仿真实验结果与分析

以中国西安市某大型公共商业建筑为研究对象,采集 2019-09-01—2019-10-21 共 1 224 组用电负荷、日天气信息和日类型信息的标准化数据,并以 2019-10-21 为预测日,使用 AP-FISOA-RBF 模型仿真预测当天的用电负荷。其中,取前 1 200 组数据用于网络训练。预测模型的固定参数请扫描论文末页右下角二维码查看表 S2,不同模型的参数训练方式请扫描论文末页右下角二维码查看表 S3。

5.1 数据处理与特征向量

AP 相似日选取的首要任务是选择合适的特征

向量. 首先, 对天气和日期类型等定性指标进行数据量化, 并归一化至 $[0, 1]$. 然后, 利用皮尔逊系数法分析量化后的数据, 获得影响建筑用电负荷的主要特征参数, 如表 2. 选取系数较大的特征向量作为 AP 聚类与预测网络的输入, 分别为历史日用电负荷(U_1)、日平均温度(U_2)和日期类型(U_3), AP 聚类的输出为 AP 簇(P), 预测网络的输出为预测日用电负荷(Y).

表 2 负荷影响因素的相关性分析

Table 2 Correlation analysis of load influencing factors

变 量	符号	皮尔逊相关性系数
历史日负荷/kW	U_1	1.000
日平均温度/℃	U_2	0.519
日期类型	U_3	0.502
日最高温度/℃	U_4	0.439
日最低温度/℃	U_5	0.372
天气类型	U_6	-0.142

5.2 AP 相似日选取

AP 相似日选取包括 AP 聚类与相似日的选取. 输入历史日负荷、日平均温度和日期类型 3 个特征向量, 采用 AP 算法进行聚类, 结果如图 3 和表 3, 得到 8 组放射状 AP 聚类结果, 同组聚类点之间具有显著相似性. 相似日编号为 $[1, 2, \dots, 50]$, 分别代表历史日 $[2019-09-01, 2019-09-02, \dots, 2019-10-20]$.

图 3 AP 聚类结果

Fig. 3 Result of AP clustering algorithm

将主要影响用电负荷的日平均温度(U_2)和日期类型(U_3)作为 2 个特征向量, 结合表 3, 利用皮尔

逊系数法筛选与预测日相关性较高的前 5 组 AP 簇, 即分别为 AP_8 、 AP_7 、 AP_1 、 AP_6 和 AP_3 对应的相似日, 从而完成相似日选取.

表 3 AP 聚类簇的相关性分析

Table 3 Correlation analysis of AP results

P	相似日编号	相关系数
AP_8	$[50, 36, 15, 43]$	0.806
AP_7	$[35, 49, 14, 22, 39, 42, 46, 18, 21]$	0.579
AP_1	$[1, 25, 28, 17, 32, 37]$	0.477
AP_6	$[29, 13, 44, 19, 38, 34, 47]$	0.461
AP_3	$[48, 41, 40, 16, 4, 31, 24, 45]$	0.453
AP_5	$[20, 33, 11, 23, 12]$	0.235
AP_4	$[8, 27, 26, 7, 10]$	0.212
AP_2	$[30, 2, 3, 5, 9, 6]$	0.178

5.3 模型评价指标

本研究采用平均绝对百分比误差(mean absolute percentage error, MAPE)和预测均方误差(mean square error, MSE)两个指标对预测模型进行评价, 计算式分别为

$$MAPE = \frac{1}{r} \sum_{i=1}^r \frac{|X_i - R_i|}{R_i} \times 100\% \quad (22)$$

$$MSE = \frac{1}{r} \sum_{i=1}^r (X_i - R_i)^2 \quad (23)$$

其中, X_i 和 R_i 分别为第 i 次采集数据的电力负荷的预测值和实际值; r 为样品采集次数. 预测模型的 MAPE 值越小表明模型的预测精度越好.

5.4 负荷预测及结果分析

本研究基于 AP-FISOA-RBF 模型预测 2019-10-21 的建筑物短期用电负荷. 结合表 2 设置 RBF 神经网络为 3-8-1 结构, 即网络输入层神经元个数 $n = 3$, 隐含层数目 $m = 8$, 输出层神经元个数 $k = 1$. 结合表 3, 对 AP_8 、 AP_7 、 AP_1 、 AP_6 和 AP_3 这 5 组 AP 相似日的数据进行训练, 确定 FISOA-RBF 模型的相似日预测权值, 计得实际预测值为

$$Y = 0.28y_1 + 0.21y_2 + 0.17y_3 + 0.17y_4 + 0.16y_5 \quad (24)$$

网络参数训练结果如表 4. 由表 4 可见, 与传统 RBF、SOA-RBF 和 PSO-RBF 模型相比, 训练后的 AP-FISOA-RBF 神经网络能够很好的逼近该非线性时间序列, 逼近能力较高, 也更易获得最佳运行效果下的最优解.

表 4 网络训练参数及运行效果
Table 4 Training network parameters and operating effects

预测模型	输入变量	变量范围	<i>C</i>	<i>B</i>	<i>W</i> 取值范围	MAPE/%	耗时/s
AP-FISOA-RBF	U_1	(0, 4 000)	[400.0, 1 300.0, 1 800.0, 2 300.0]	[400.0, 400.0, 200.0, 200.0]	(0, 3 400.00)	2.26	5.01
	U_2	(-10, 50)	[14.0, 23.0]	[3.5, 5.0]	(-0.50, 42.50)		
	U_3	(0, 1)	[0.6, 0.7]	[0.1, 0.2]	(0, 0.85)		
SOA-RBF	U_1	(0, 4 000)	[500.0, 1 000.0, 2 000.0, 2 600.0]	[320.0, 520.0, 560.0, 600.0]	(0, 3 400.00)	2.84	7.47
	U_2	(-10, 50)	[10.0, 20.0]	[5.0, 4.5]	(-0.50, 42.50)		
	U_3	(0, 1)	[0.6, 0.8]	[0.3, 0.3]	(0, 0.85)		
PSO-RBF	U_1	(0, 4 000)	[600.0, 1 500.0, 1 800.0, 2 100.0]	[460.0, 550.0, 550.0, 500.0]	(0, 4 000.00)	5.00	9.35
	U_2	(-10, 50)	[17.0, 26.0]	[5.0, 5.0]	(-10.00, 50.00)		
	U_3	(0, 1)	[0.7, 0.8]	[0.3, 0.2]	(0, 1.00)		
RBF	U_1	(0, 4 000)	[450.0, 1 100.0, 2 000.0, 2 500.0]	[400.0, 400.0, 400.0, 300.0]	(0, 4 000.00)	11.80	12.44
	U_2	(-10, 50)	[10, 30]	[4.00, 5.00]	(-10.00, 50.00)		
	U_3	(0, 1)	[0.5, 0.7]	[0.2, 0.3]	(0, 1.00)		

图 4 和图 5 为采用 RBF、PSO-RBF、SOA-RBF 和 AP-FISOA-RBF 算法进行建筑用电负荷预测的结果. 可见, 与传统的 RBF、PSO-RBF 和 SOA-RBF 预测模型相比, AP-FISOA-RBF 模型的拟合度更高, 预测结果更贴近真实值, MAPE 值分别降低了 93.05%、83.60% 和 71.13%, MSE 值分别降低了 95.30%、87.57% 和 73.23%. 综上, 采用融合策略改进后的 FISOA 算法比常规 PSO 和 SOA 算法性能更好, 全局寻优性能更强, 尤其是在对历史数据

图 4 RBF、PSO-RBF、SOA-RBF 和 AP-FISOA-RBF 模型的建筑电力负荷日预测结果
Fig. 4 (Color online) Comparison of daily load forecasting results based on RBF、PSO-RBF、SOA-RBF、AP-FISOA-RBF mode

图 5 建筑用电负荷日预测误差对比
Fig. 5 (Color online) Comparison of absolute errors of load forecasting

进行 AP 聚类处理后, 可显著提升 FISOA-RBF 的预测精度.

采用聚类算法 (k -means、模糊 c -means 和 AP) 和无聚类算法 (AR、SVR、GM、RBF、PSO-RBF、SOA-RBF 和 FISOA-RBF), 计算建筑用电负荷预测的 MAPE 值、MSE 值和模型运行的耗时, 结果如表 5. 所有结果都是运行 10 次后的平均值.

分析表 5 可知, 无聚类算法处理下, RBF 模型的 MAPE 值比其他采用单一算法模型更小, 即预测结果更稳定, 证明采用 RBF 神经网络的合理性. 其

中, FISOA-RBF 模型的预测误差最小, 更贴近真实值. 可见, 融合改进策略能够使 FISOA 算法更好地优化 RBF 网络参数, 弥补了梯度下降法进行参数调整的不足, 提高了传统 RBF 的预测性能. 采用 AP 聚类后, AP-FISOA-RBF 模型预测的 MAPE 低至 0.82%, MSE 低至 805.17 kW², 比无聚类算法的 FISOA-RBF 模型降低了 68.05%, 明显减少了外界环境对负荷预测的影响, 增强了模型的稳定性. 但是, k -means 和模糊 c -means 算法因初始聚类中心及聚类数难以设定, 预测时长和误差均显著增加.

分析模型运行耗时结果发现, 虽然传统的 RBF 模型的预测时间较长, 但优化后训练速度均能得到显著提高, AP-FISOA-RBF 模型的平均预测速度比传统 RBF、PSO-RBF 和 SOA-RBF 模型分别提高了 54.34%、39.25% 和 23.96%, 收敛速度显著提高.

表 5 不同模型的预测性能

Table 5 Performance errors of different models

预测模型	MAPE/%	MSE/kW ²	耗时/s
AR	14.12	19 013.12	8.62
SVR	12.25	17 731.11	12.68
GM	12.00	16 931.46	8.52
RBF	11.80	17 142.65	12.44
PSO-RBF	5.00	6 477.12	9.35
SOA-RBF	2.84	3 007.19	7.47
FISOA-RBF	2.26	2 520.23	5.01
k -means-FISOA-RBF	2.03	2 011.78	7.83
模糊 c -means-FISOA-RBF	1.85	1 837.88	8.01
AP-FISOA-RBF	0.82	805.17	5.68

结 语

结合 SOA 算法的全局搜索性能, 改进后的 FISOA 算法可对 RBF 网络的中心、权值和宽度参数进行更准确有效的全局寻优. 同时, AP 相似日选取的应用能有效克服天气和日期类型等影响, 快速且准确地处理大量样本数据. 相比传统的 PSO 和 SOA 算法, 采用融合策略的 FISOA 算法能明显优化 RBF 网络. 自适应搜索速度和多人协同搜索模式显著加快了对 RBF 参数的寻优速度, 精英后代遗传策略明显降低了子代种群的随机性, 提高了解的质量. 综上可见, 本研究提出的 AP-FISOA-RBF 预测模型受输入影响较小, 在预测精度和收敛速度上均

有较好的表现, 证明了模型在高精度用电负荷预测方面的有效性和可靠性.

基金项目: 陕西省重点研发计划项目 (社发领域) (2017ZDL-SF-16-5); 安徽建筑大学智能建筑与建筑节能安徽省重点实验室开放课题资助项目 (Z201990383)

作者简介: 于军琪 (1969—), 西安建筑科技大学教授. 研究方向: 智能建筑. E-mail: junqiyu@126.com

引 文: 于军琪, 王佳丽, 赵安军, 等. 基于 AP 相似日选取与 FISOA-RBF 的短期负荷预测[J]. 深圳大学学报理工版, 2021, 38(3): 315-323.

参考文献 / References:

- [1] 侯恩哲. 《中国建筑能耗研究报告 (2017)》概述[J]. 建筑节能, 2017, 45(12): 131.
HOU Enzhe. Overview of China building energy consumption research report: 2017 [J]. Journal of Building Energy Efficiency, 2017, 45(12): 131. (in Chinese)
- [2] 于惠鸣, 张智晟, 龚文杰, 等. 基于深度递归神经网络的电力系统短期负荷预测模型[J]. 电力系统及其自动化学报, 2019, 31(1): 112-116.
YU Huiming, ZHANG Zhisheng, GONG Wenjie, et al. Short-term load forecasting model of power system based on deep recurrent neural network [J]. Proceedings of the CSU-EPSSA, 2019, 31(1): 112-116. (in Chinese)
- [3] YE Zhaoyang, KIM M K. Predicting electricity consumption in a building using an optimized back propagation and Levenberg-Marquardt back-propagation neural network: case study of a shopping mall in China [J]. Sustainable Cities and Society, 2018, 42: 176-183.
- [4] 万 昆, 柳瑞禹. 区间时间序列向量自回归模型在短期电力负荷预测中的应用[J]. 电网技术, 2012, 36(11): 77-81.
WAN Kun, LIU Ruiyu. Application of interval time-series vector autoregressive model in short-term load forecasting [J]. Power System Technology, 2012, 36(11): 77-81. (in Chinese)
- [5] CHEN Yibo, TAN Hongwei. Short-term prediction of electric demand in building sector via hybrid support vector regression [J]. Applied Energy, 2017, 204: 1363-1374.
- [6] 张志明, 金 敏. 基于灰关联分段优选组合模型的短期电力负荷预测研究[J]. 电工技术学报, 2009, 24(6): 115-120.
ZHANG Zhiming, JIN Min. Research on short-term electrical load forecasting based on optimized combination grey correlation segmentation [J]. Transactions of China Electrotechnical Society, 2009, 24(6): 115-120. (in Chinese)
- [7] 李方伟, 张新跃, 朱 江, 等. 基于 APDE-RBF 神经网络的网络安全态势预测方法[J]. 系统工程与电子技术, 2016, 38(12): 2869-2875.
LI Fangwei, ZHANG Xinyue, ZHU Jiang, et al. Network security situation prediction based on APDE-RBF neural network [J]. Systems Engineering and Electronics,

- 2016, 38(12): 2869-2875. (in Chinese)
- [8] 刘威, 付杰, 周定宁, 等. 基于反时限混沌郊狼优化算法的BP神经网络参数优化[J/OL]. 控制与决策, 2020. 04. 08, <https://doi.org/10.13195/j.kzyjc.2020.0408>.
LIU Wei, FU Jie, ZHOU Dingning, et al. Parameter optimization of BP neural network based on coyote optimization algorithm with inverse time chaotic [J]. Control and Decision. [2020-04-08]. <https://doi.org/10.13195/j.kzyjc.2020.0408>. (in Chinese)
- [9] 片锦香, 浦春钰, 戚爱伟, 等. 基于RBF的机械主轴振动预报模型[J]. 控制工程, 2019, 26(12): 2193-2198.
PIAN Jinxiang, PU Chunyu, QI Yuanwei, et al. Mechanical spindle vibration prediction model based on RBF network [J]. Control Engineering of China, 2019, 26(12): 2193-2198. (in Chinese)
- [10] 于泉, 刘洋, 郭晓伟. 基于路口相关性的交通流量修复研究[J]. 深圳大学学报理工版, 2019, 36(3): 304-309.
YU Quan, LIU Yang, GUO Xiaowei. Restoration of traffic flow data based on intersection correlation [J]. Journal of Shenzhen University Science and Engineering, 2019, 36(3): 304-309. (in Chinese)
- [11] CHENG M L, CHIA-NAN K. Time series prediction using RBF neural networks with a nonlinear time-varying evolution PSO algorithm [J]. Neurocomputing, 2009, 73: 449-460.
- [12] 回立川, 于森, 梁芷睿. 应用近邻传播算法改进RBF的短期负荷预测[J]. 电力系统及其自动化学报, 2015, 27(1): 69-73.
HUI Lichuan, YU Miao, LIANG Zhirui. Research on electrical load short-term forecasting via radial basis function neural network designed by affinity propagation [J]. Proceedings of the CSU-EPSCA, 2015, 27(1): 69-73. (in Chinese)
- [13] 翟莹莹, 左丽, 张恩德. 基于参数优化的RBF神经网络结构设计算法[J]. 东北大学学报自然科学版, 2020, 41(2): 176-181, 187.
ZHAI Yingying, ZUO Li, ZHANG Ende. Algorithm for structure design of rbf neural network based on parameter optimization [J]. Journal of Northeastern University Natural Science, 2020, 41(2): 176-181, 187. (in Chinese)
- [14] DAI Chaohua, CHEN Weirong, ZHU Yunfang, et al. Seeker optimization algorithm for tuning the structure and parameters of neural networks [J]. Neurocomputing, 2011, 74(6): 876-883.
- [15] 陈尚巧, 王明春, 张雨飞, 等. 基于PSO-SOA融合算法的PID参数优化[J]. 工业控制计算机, 2019, 32(10): 22-24, 27.
CHENG Shangqiao, WANG Mingchun, ZHANG Yufei, et al. PID parameter optimization based on PSO-SOA fusion algorithm [J]. Industrial Control Computer, 2019, 32(10): 22-24, 27. (in Chinese)
- [16] 杨俊华, 邹子君, 杨金明, 等. 基于人群搜索算法的波浪发电系统最优负载[J]. 太阳能学报, 2019, 40(10): 2725-2731.
YANG Junhua, ZOU Zijun, YANG Jinming, et al. Optimal load of wave power generation system based of seeker optimization algorithm [J]. Acta Energiae Solaris Sinica, 2019, 40(10): 2725-2731. (in Chinese)
- [17] CHEN Chunchao, LI Jinsong, LUO Jun, et al. Seeker optimization algorithm for optimal control of manipulator [J]. The Industrial Robot, 2016, 43(6): 667-686.
- [18] 何莉, 肖茗方, 张威亚. 采用人群搜索算法的径向基函数神经网络参数整定方法[J]. 华侨大学学报自然科学版, 2018, 39(2): 299-305.
HE Li, XIAO Mingfang, ZHANG Weiya. Parameter method of radial basis function neural network using adjusting seeker optimization algorithm [J]. Journal of Huaqiao University Natural Science, 2018, 39(2): 299-305. (in Chinese)
- [19] 谷云东, 马冬芬, 程红超. 基于相似数据选取和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学报, 2019, 31(5): 64-69.
GU Yundong, MA Dongfen, CHENG Hongchao. Power load forecasting based on similar-data selection and improved gradient boosting decision tree [J]. Proceedings of the CSU-EPSCA, 2019, 31(5): 64-69. (in Chinese)
- [20] 曹愈远, 张博文, 李艳军. AP聚类改进免疫算法用于航空发动机故障诊断[J]. 航空动力学报, 2019, 34(8): 1795-1804.
CAO Yuyuan, ZHANG Bowen, LI Yanjun. AP clustering improved immune algorithm for aero-engine fault diagnosis [J]. Journal of Aerospace Power, 2019, 34(8): 1795-1804. (in Chinese)
- [21] 冷亚军, 吴宗育, 赵文会, 等. 基于近邻传播聚类权重的黑启动方案评估方法[J]. 电力系统自动化, 2020, 44(13): 73-84.
LENG Yajun, WU Zongyu, ZHAO Wenhui, et al. Assessment method of black-start scheme based on affinity propagation clustering weight [J]. Automation of Electric Power Systems, 2020, 44(13): 73-84. (in Chinese)
- [22] 高毅, 李盛伟, 迟福建, 等. 基于SOA-WNN的光伏短期输出功率预测[J]. 电力系统及其自动化学报, 2019, 31(6): 62-66.
GAO Yi, LI Shengwei, CHI Fujian, et al. Photovoltaic short-term output power forecasting based on SOA-WNN [J]. Proceedings of the CSU-EPSCA, 2019, 31(6): 62-66. (in Chinese)

【中文责编: 英子; 英文责编: 木柯】

补充材料

<http://journal.szu.edu.cn>