

DOI: 10.19783/j.cnki.pspc.201150

基于智能优化方法的相似日短期负荷预测

陈弘川¹, 蔡旭¹, 孙国歧², 魏晓宾², 曹云峰¹, 孙学锋², 苏辉², 张玲艳²

(1. 上海交通大学, 上海 200240; 2. 山东德佑电气股份有限公司, 山东 淄博 255049)

摘要: 针对传统相似日法中各因素相似度及其权重需要人工赋值的不足, 在充分考虑日期类型、日期距离、气象因素等几种主要常规影响因子的前提下, 建立了一种基于智能优化方法的相似日模型对日用电量进行短期预测。相似度计算公式中全部原本需要人工赋值的参数均由历史数据基于果蝇优化算法训练得出。参数值可以根据特定用户的负荷变化特性动态调整, 增强了相似日法的准确性和通用性。为了解决求解参数的多维优化问题, 避免算法陷入局部极值, 提出了一种引入多种群概念的果蝇优化算法, 增强了算法的全局搜索能力。仿真实例表明, 相比起传统的相似日模型, 基于智能优化方法的相似日模型的预测准确率有了明显提高。

关键词: 短期负荷预测; 相似日; 参数自适应; 果蝇优化算法

Similar day short-term load forecasting based on intelligent optimization method

CHEN Hongchuan¹, CAI Xu¹, SUN Guoqi², WEI Xiaobin², CAO Yunfeng¹, SUN Xuefeng², SU Hui², ZHANG Lingyan²
(1. Shanghai Jiaotong University, Shanghai 200240, China; 2. Shandong Deyou Electric Co., Ltd., Zibo 255049, China)

Abstract: In order to overcome the shortcomings of the traditional similar day method that each factor and its weight need to be manually assigned, this paper establishes a similar day model based on intelligent optimization method to predict daily electricity consumption by fully considering several main conventional influencing factors such as date type, date distance and meteorological factors. All the parameters in the similarity calculation formula that used to be manually assigned are trained from historical data by using fruit fly optimization algorithm. The parameter values can be dynamically adjusted according to the load change characteristics of specific users, which enhances the accuracy and versatility of the similar day method. In order to solve the multi-dimensional optimization problem of parameter training and avoid the algorithm from falling into local extremum, this paper proposes an improved fruit fly optimization algorithm that introduces the concept of multiple groups to enhance the algorithm's global searching ability. The simulation example shows that compared with the traditional similar day model, the prediction accuracy of the similar day model based on intelligent optimization method has been significantly improved.

This work is supported by the Key Research and Development Program of Shandong Province (No. 2019JZZY020804).

Key words: short-term load forecasting; similar day; parameter adaptation; fruit fly algorithm

0 引言

短期负荷预测是以日为单位的预测, 它是电力调度部门运行和规划的重要依据, 准确的短期负荷预测可以帮助电力部门合理安排检修计划、运行方式、日开停机、发电计划等^[1]。目前, 短期负荷预测方法有很多, 主要可以分为两类, 一种是仅仅通过历史负荷的走向预测未来负荷的趋势, 如时间序列法^[2]、灰色理论法^[3-4]、卡尔曼滤波法^[5-6]、支持

向量机^[7-8]等, 第二种是综合考虑历史负荷及其影响因素对未来负荷进行预测, 如相似日法^[9-11]、专家系统法^[12]等。相似日法不仅综合考虑了各因素对电力负荷的影响, 还具有原理简单、应用方便、效果良好等优点, 在短期负荷预测层面得到广泛应用。

相似日法顾名思义就是要找到与预测日相似的日期, 在这些日期里, 影响负荷变化的因素如日期类型、季节类型、气温等, 具有相似性, 将这些影响因素组合形成一个向量用于描述某一天的日特征, 通过查找日特征相似度最高的日期为预测的相似日。一个有效的相似日法模型, 相似度最高的历

基金项目: 山东省重点研发计划项目资助(2019JZZY020804)

史日理可以反映预测日的负荷使用情况。因此，相似度的计算是相似日法的关键。相似度的计算公式中包含各影响因素的相似度及其权重，传统方法中对各因素相似度及其权重一般采取人工赋值的方式，相似日法预测的准确度完全依赖于人工经验。

以日类型相似度为例，文献[13]将日类型划分为工作日和周末，日类型相同时，相似度取 1，不相同时取 0.5。这种简单区分工作日和周末的方法比较粗糙，实际上，周一负荷会受到周日负荷的影响，周五负荷也会因为周六的到来与一般工作日(周二到周四)有所不同。文献[14-15]根据地区特性，将一周划分为五个或更多的日期类型，根据专家经验设置不同日期类型的映射值，日类型相似度的计算采取的是预测日和历史日日类型映射值之差。人工设置映射值要求对用户负荷变化特性十分了解，但由于存在主观性，难免会产生误差，对预测精度造成影响。针对不同的用户，需要根据负荷变化特性设置与其对应的映射值，该方法的通用性不强。

对于各因素的权重，传统方法一般采用固定权重系数，不能有效识别主导因素的影响。文献[16]通过灰色关联分析法计算气象因素特征向量的匹配系数，不足之处在于总体相似度的计算是取各影响因素匹配系数的平均值，没有考虑不同因素对于负荷预测的权重占比；文献[17-18]动态调整各影响因素的权重系数，但仍需人工设置星期类型的映射值，参数自适应程度可以进一步改善。

针对这些方法的不足，本文在计算相似度时，把相似度计算公式中全部原本需要人工赋值的参数通过历史数据训练得出，无需人工设置各因素相似度及其权重，增强了相似日法的准确性和通用性。

训练相似日模型中各参数的过程实际上是最优化的过程，借助有效的优化算法，能在较短时间内找到最优参数。和其他优化算法相比，果蝇优化算法(Fruit Fly Optimization Algorithm, FOA)具有原理简单、调节参数少、计算量小、程序代码易实现、全局寻优能力强等优点^[19-24]，适合求解中小型的多峰优化问题，因此选择果蝇优化算法作为参数自适应过程的求解算法。

将果蝇优化算法用于求解相似日法模型参数问题的难点在于，求解参数的过程是一个多维优化问题，单个维度的改变可能不会引起最终结果的变化，算法容易陷入局部极值。为了使果蝇优化算法适应多维优化问题、避免陷入局部极值，本文引入多种群的概念，对果蝇优化算法进行改进，每个果蝇种群的气味信息相互独立、互不影响，果蝇个体分别在各自种群内部迭代寻优，迭代结束后再找出所有

果蝇个体中最优味道浓度所对应的位置坐标。通过引入多种群概念使果蝇优化算法具有较强的全局搜索能力，从而实现更快的收敛速度。

本文在充分考虑日期类型、日期距离、气象因素等几种主要常规影响因子的前提下，提出了一种基于智能优化方法对日用电量进行短期预测的相似日模型，相似日模型中的参数值可以根据特定用户的负荷变化特性动态调整。为了解决求解参数的多维优化问题、避免算法陷入局部极值，本文提出了一种引入多种群概念的果蝇优化算法，增强了算法的全局搜索能力。通过对实际负荷数据进行仿真，证明了相比起传统的相似日模型，本文建立的基于智能优化方法的相似日模型的预测准确率有了明显提高。

1 基于智能优化方法的相似日模型

1.1 日特征向量的选取及赋值

相似日法的第一步是选取日特征向量，即影响电力负荷变化的因子，日特征向量选取的好坏将直接影响相似日法预测的准确度。在正确找出相似日特征后，要对这些特征加以赋值，还要对无法直接用数值表示的特征进行量化处理。

在一般情况下，影响日用电量的因素主要包括日期类型、日期距离、气温、湿度等，将这些因素组成日特征向量并进行赋值，赋值规则如表 1 所示。

表 1 日特征向量的组成和赋值规则

Table 1 Composition and assignment rules of daily eigenvectors

因素	描述符号	赋值规则
日类型	D	$D =$ 周一~周日
日期距离	d	单位为天数
日平均气温	T	单位为摄氏度
平均相对湿度	H	单位为百分比

1.2 日特征相似度的计算

如果预测日和历史日的日类型相同，则相似度为 1；否则，如果预测日和历史日中有一天是周一，另一天是周二，则这两日的日类型相似度为 $F_{1,2}$ ；如果预测日和历史日中有一天是周一，另一天是周三，则相似度为 $F_{1,3}$ ，依此类推，如表 2 所示。

根据理论分析可以知道，表 2 是沿着对角线对称的，因此只有 21 个不同日类型的相似度，它们的取值都在 0 到 1 之间，由下文的参数自适应过程训练得出。根据用户负荷特性的不同它们的取值也会不同。日用电量基本不随日类型变化的用户，如商场、火车站等，不同日类型相似度的取值会相对均匀；工作日和休息日日用电量会有明显区别的用户，如办公室、居民楼等，工作日和休息日的相

似度会有明显差异。

表 2 不同日类型的相似度
Table 2 Similarity of different day types

	周一	周二	周三	周四	周五	周六	周日
周一	1	$F_{1,2}$	$F_{1,3}$	$F_{1,4}$	$F_{1,5}$	$F_{1,6}$	$F_{1,7}$
周二	$F_{1,2}$	1	$F_{2,3}$	$F_{2,4}$	$F_{2,5}$	$F_{2,6}$	$F_{2,7}$
周三	$F_{1,3}$	$F_{2,3}$	1	$F_{3,4}$	$F_{3,5}$	$F_{3,6}$	$F_{3,7}$
周四	$F_{1,4}$	$F_{2,4}$	$F_{3,4}$	1	$F_{4,5}$	$F_{4,6}$	$F_{4,7}$
周五	$F_{1,5}$	$F_{2,5}$	$F_{3,5}$	$F_{4,5}$	1	$F_{5,6}$	$F_{5,7}$
周六	$F_{1,6}$	$F_{2,6}$	$F_{3,6}$	$F_{4,6}$	$F_{5,6}$	1	$F_{6,7}$
周日	$F_{1,7}$	$F_{2,7}$	$F_{3,7}$	$F_{4,7}$	$F_{5,7}$	$F_{6,7}$	1

在大多数情况下, 两天的日期距离越近, 它们的负荷曲线越相似, 在选择相似日时, 有明显的“近大远小”规则, 因此需要将日期距离列入影响因素的考虑中。但是, 日期距离对负荷变化的影响具有明显的饱和效应。例如, 历史日与预测日相隔一天或一星期, 两者有明显区别, 但是历史日与预测日相隔 3 个星期或 4 个星期, 其相似度则没有明显区别。一些地区, 夏季可能出现持续 20 天甚至更长时间的高温天气, 然后出现降雨、突然降温, 在近 20 天内没有相似日, 如果该因素的相似度随着日期距离的增大持续减小, 则距离远的日期没有入选的可能性, 不能准确预测^[18]。因此, 需要设定该因素的相似度下限。

日期距离的相似度的计算公式为

$$F_d = \begin{cases} \beta^d & \text{if } \beta^d \geq a \\ a & \text{otherwise} \end{cases} \quad (1)$$

式中: d 为历史日与预测日的间隔天数; β 为衰减系数, 含义是历史日与待预测日的距离每增加一天的相似度缩减比率, 一般取 0.95; a 为该因素的最低相似度, 由下文的参数自适应过程训练得出。

气象因素相似度是为了衡量预测日与历史日在气象上的相似程度, 选取日平均气温、日平均相对湿度组成气象因素特征向量, 用灰色关联分析来计算气象因素相似度^[14]。

预测日及距离预测日的第 i 个历史日的气象因素特征向量分别用 X_0 、 X_i 来表示, 预测日的气象因素特征向量为 $X_0 = \{X_0(1), X_0(2)\}$, $X_0(1)$ 、 $X_0(2)$ 分别是预测日的日平均气温和日平均相对湿度, 第 i 个历史日的气象因素特征向量为 $X_i = \{X_i(1), X_i(2)\}$, $X_i(1)$ 、 $X_i(2)$ 分别是第 i 个历史日的日平均气温和日平均相对湿度。

预测日与第 i 个历史日在第 k 个特征的差异为

$$\Delta_i(k) = |X_i(k) - X_0(k)| \quad (2)$$

将差异值进行归一化, 计算公式为

$$\Delta'_i(k) = \frac{\Delta_i(k) - \min_p \Delta_p(k)}{\max_p \Delta_p(k) - \min_p \Delta_p(k)} \quad (3)$$

预测日与第 i 个历史日在第 k 个特征的关联系数为

$$\zeta_i(k) = \frac{\min_p \min_q \Delta'_p(q) + \rho \max_p \max_q \Delta'_p(q)}{\Delta'_i(k) + \rho \max_p \max_q \Delta'_p(q)} \quad (4)$$

式中, ρ 是一个介于 0 与 1 之间的常数, 一般取 $\rho = 0.5$ 。

综合气温和湿度的关联系数, 得到预测日与第 i 个历史日的气象因素关联度为

$$r_i = \frac{\zeta_i(1) + \zeta_i(2)}{2} \quad (5)$$

由式(4)和式(5)可以看出, 温度和湿度的差异越小, 关联系数越大, 预测日与历史日的气象因素关联度也越大。因此, 可以取关联度作为气象因素的相似度。

用日特征相似度来表征预测日与历史日在所有影响因素下的总体相似程度, 日特征相似度的数值在 0 到 1 之间, 其值越大, 表示预测日与历史日的日特征越相似。为了表征日特征向量中各因素对负荷变化的影响程度, 引入因素权重系数。

日特征相似度的计算公式为

$$L = F_{p,q}^{\lambda_w} \times F_d^{\lambda_d} \times F_m^{\lambda_m} \quad (6)$$

式中: $F_{p,q}$ 代表日类型的相似度; F_d 代表日期距离的相似度; F_m 代表气象因素的相似度; λ_w 、 λ_d 、 λ_m 分别代表对应因素的权重, 取值在 0 到 1 之间, 因素的权重越大, 意味着该因素对负荷变化的影响程度越大。各因素的权重系数同样由下文的参数自适应过程训练得出。

1.3 参数自适应研究

1.2 节提出的基于智能优化方法的相似日模型需要训练 25 个参数, 包括 21 个不同日类型的相似度、日期距离的最低相似度和 3 个因素的权重系数, 采用下文提出的改进果蝇优化算法利用历史数据训练参数, 将预测日的最近 14 日设为相似日粗集, 粗集中与预测日的日特征相似度最高的一日即为第 1 相似日。

用相对误差(Relative Error, RE)来衡量日用电量预测的误差, 相对误差的计算公式为

$$RE = \frac{Q' - Q}{Q} \times 100\% \quad (7)$$

式中: Q' 表示预测的日用电量; Q 表示实际的日用电量。

不断调整各因素的权重系数,使得在训练样本中,从粗集中选取的第1相似日对日用电量进行预测的误差之和最小。

参数自适应过程实际上是一个优化过程,25个决策变量分别是21个不同日类型的相似度、日期距离的最低相似度和3个因素的权重系数,目标函数是训练样本中通过相似日法选取的第1相似日的预测误差之和最小,约束条件是各决策变量的定义域均在0到1之间。

1.4 基于智能优化相似日模型短期预测基本步骤

建立基于智能优化方法的相似日模型对日用电量进行短期预测的基本步骤如下。

步骤一:读取日类型、日平均气温、日平均相对湿度等负荷特性影响因子数据以及历史负荷数据;

步骤二:确定训练样本集,采用改进的果蝇优化算法求解21个不同日类型的相似度、日期距离的最低相似度和3个因素的权重系数;

步骤三:采用训练好的相似日模型计算各历史日与预测日的日特征相似度;

步骤四:选取日特征相似度最大的一个历史日作为预测日的第1相似日,用第1相似日的日用电量预测预测日的日用电量。

建立基于智能优化方法的相似日模型对日用电量进行短期预测的流程图如图1所示。

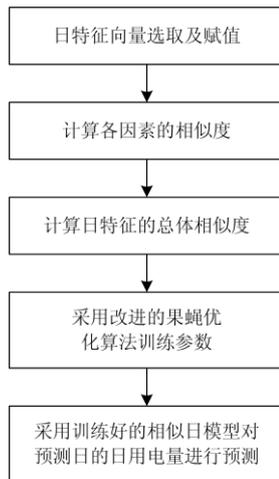


图1 基于智能优化方法的相似日模型预测流程图

Fig. 1 Flowchart of similar day model prediction based on intelligent optimization method

2 用于训练参数的改进果蝇优化算法

为了求解相似日模型中的参数,以每个果蝇个体的位置坐标代表满足约束条件的一组参数,其中包括21个不同日类型的相似度、日期距离的最低相

似度和3个因素的权重系数。优化问题的维度是二十五维,具体求解步骤如下。

步骤一:设置最大迭代次数($Iter_{max}$)、种群数量($groupsize$)、种群规模($popsize$)。

步骤二:在定义域内随机产生 $groupsize$ 个果蝇种群的初始位置,果蝇个体的初始位置可以表示为 $X_i^* = \{x_1^*, x_2^*, \dots, x_{25}^*\}$,其中 i 是果蝇所属种群, $i = 1, 2, \dots, groupsize$ 。

步骤三:每个果蝇种群中有 $popsize$ 个果蝇个体,对于每个果蝇个体,赋予其从初始位置出发一个随机的飞行方向和距离,即飞行后终点将是飞行方向定义域的内任何值。 $X_{i,j} = (x_{i,j,1}, x_{i,j,2}, \dots, x_{i,j,25})$ 是第 i 个果蝇种群中的第 j 个果蝇个体所对应的位置坐标,设 $d_{i,j}$ 为1到25之间的一个随机整数,那么有式(8)成立。

$$x_{i,j,r} = \begin{cases} rand & \text{if } r = d_{i,j} \\ x_i^* & \text{otherwise} \end{cases} \quad (8)$$

式中: $i = 1, 2, \dots, groupsize$; $j = 1, 2, \dots, popsize$; $rand$ 表示生成一个在0到1间的随机数。

步骤四:将所有果蝇个体的位置坐标代入味道浓度判定函数,计算每个果蝇个体所对应的味道浓度。将味道浓度判定函数记作 $Smell$,该问题下的味道浓度判定函数是指在当前相似日的模型下,训练样本中每一日用相似日法选取的第1相似日进行预测的误差之和。

步骤五:上一代每个种群的最优味道浓度记为 $bestSmell_i^*$,记录每个种群中味道浓度优于上代最优味道浓度的果蝇个体所对应的位置坐标。

步骤六:对于每个种群,将当前果蝇群体中所有味道浓度优于上代最优味道浓度的果蝇个体对应的位置坐标组合成一个新的果蝇个体位置 $X_i^{new} = (x_{i,1}^{new}, x_{i,2}^{new}, \dots, x_{i,25}^{new})$,其中第 r ($r = 1, 2, \dots, 25$)个分量的值 $x_{i,r}^{new}$ 等于所有在第 r 个分量上变化的果蝇个体中味道浓度最优的一个。

$$x_{i,r}^{new} = \begin{cases} x_{i,j,r} & \text{if } \min(Smell(X_{i,j})) < bestSmell_i^* \\ x_i^* & \text{otherwise} \end{cases} \quad (9)$$

步骤七:对于每个种群,判断当前果蝇群体中的最优味道浓度或新果蝇的味道浓度是否优于前一次迭代的最优味道浓度 $bestSmell_i^*$,若是则更新最优味道浓度 $bestSmell_i^*$ 和记录最优味道浓度所对应的果蝇个体的位置。

步骤八:对于每个种群,群体中的果蝇均飞向当前群体最优味道浓度的所在位置,算法进入迭代

寻优, 重复步骤三到步骤八, 直到迭代次数达到 $Iter_{max}$ 。

步骤九: 迭代完成后, 选取在所有种群中最优味道浓度对应的果蝇个体的位置作为最优参数, 结束算法。

改进的果蝇优化算法的流程图如图 2 所示。

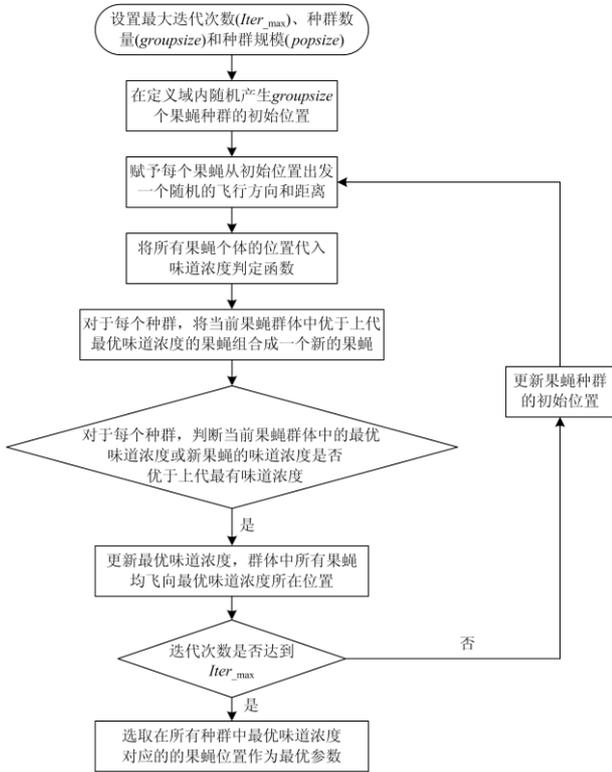


图 2 改进的果蝇优化算法流程图

Fig. 2 Improved fruit fly optimization algorithm flowchart

3 仿真实例

仿真实例的样本数据是 4 月 1 日至 6 月 7 日的某电力负荷数据, 其中 4 月 1 日至 5 月 10 日(共 40 天)的数据用来训练参数, 5 月 11 日至 6 月 7 日(共 28 天)的数据用来检验模型。

采用改进的果蝇优化算法训练参数, 果蝇种群数量($groupsize$)取 100, 种群规模($popsiz$)取 100, 最大迭代次数($Iter_{max}$)取 100, 训练得到的参数如表 3、表 4 所示。

采用训练好的相似日模型对 5 月 11 日至 6 月 7 日的日用电量进行预测, 预测结果和预测误差分别如图 3 和图 4 所示。

为了验证本文提出的模型, 将传统相似日模型的预测结果作为比对。在传统相似日模型中, 日类型相似度的计算采取文献[12]的方法, 即将日类型分为工作日和周末, 日类型相同时相似度取 1, 不

表 3 日类型相似度的取值

	周一	周二	周三	周四	周五	周六	周日
周一	1						
周二	0.095 3	1					
周三	0.939 2	0.843 9	1				
周四	0.965 8	0.966 3	0.329 6	1			
周五	0.973 5	0.995 5	0.966 2	0.556 5	1		
周六	0.118 5	0.080 2	0.167 9	0.651 2	0.839 7	1	
周日	0.546 6	0.874 2	0.960 2	0.888 5	0.467 4	0.950 7	1

表 4 其他参数的取值

日期距离最低相似度	日类型权重	日期距离权重	气象因素权重
0.5278	0.751 7	0.132 7	0.183 6

相同则取 0.5; 总体相似度的计算采取文献[15]的方法, 即认为不同影响因素的权重占比是相等的, 总体相似度的计算公式为

$$L = F_{p,q} \times F_d \times F_m \quad (10)$$

式中: $F_{p,q}$ 代表日类型的相似度; F_d 代表日期距离的相似度; F_m 代表气象因素的相似度。

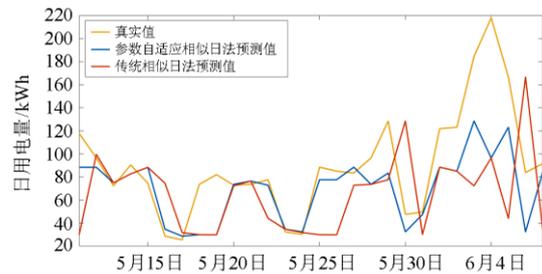


图 3 预测结果

Fig. 3 Prediction result

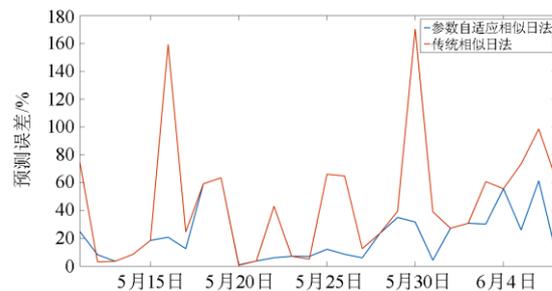


图 4 预测误差比较

Fig. 4 Prediction error comparison

在图 3 中, 黄色曲线代表日用电量的真实值, 蓝色曲线代表基于智能优化方法的相似日模型的预测值, 红色曲线代表传统相似日模型的预测值; 在

图 4 中, 蓝色曲线代表基于智能优化方法的相似日模型的预测误差, 红色曲线代表传统相似日模型的预测误差。图 4 中, 基于智能优化方法的相似日模型的平均预测误差是 21.72%, 而传统相似日模型的平均预测误差则高达 46.45%。相比传统的相似日模型, 基于智能优化方法的相似日模型的预测准确率有了明显提高。

4 结论

针对传统相似日模型中各因素相似度及其权重需要人工赋值的不足, 本文建立了一种基于智能优化方法的相似日模型对日用电量进行短期预测, 相似度计算公式中全部原本需要人工赋值的参数均由历史数据基于改进的果蝇优化算法训练得出, 参数值可以根据特定用户的负荷变化特性动态调整, 增强了相似日法的准确性和通用性。通过对某电力负荷的短期预测表明, 对比传统的相似日模型, 基于智能优化方法的相似日模型可以有效地提高短期负荷预测的准确率。

参考文献

- [1] 朱清智, 董泽, 马宁. 基于即时学习算法的短期负荷预测方法[J]. 电力系统保护与控制, 2020, 48(7): 92-98.
ZHU Qingzhi, DONG Ze, MA Ning. Forecasting of short-term power based on just-in-time learning[J]. Power System Protection and Control, 2020, 48(7): 92-98.
- [2] 范金骥. 基于 ARMA 与 ANN 模型组合交叉方法的电网日负荷预测[J]. 浙江电力, 2018, 37(8): 35-41.
FAN Jinji. Daily grid load forecasting based on ARMA and ANN model combined crossing method[J]. Zhejiang Electric Power, 2018, 37(8): 35-41.
- [3] 金鑫. 基于灰色理论的短期电力负荷预测系统设计与实现[D]. 杭州: 浙江工业大学, 2016.
JIN Xin. Design and implementation of short-term power load forecasting system based on grey theory[D]. Hangzhou: Zhejiang University of Technology, 2016.
- [4] SREEKUMAR S, VERMA J, SUJIL A, et al. An approach towards real time short term load forecasting using grey index models for smart grid framework[J]. WSEAS Transactions on Power Systems, 2016, 11(3): 147-155.
- [5] ZHENG Z, CHEN H, LUO X. A Kalman filter-based bottom-up approach for household short-term load forecast[J]. Applied Energy, 2019, 250: 882-894.
- [6] HUANG L, YANG Y, ZHAO H, et al. Time series modeling and filtering method of electric power load stochastic noise[J]. Protection and Control of Modern Power Systems, 2017, 2(3): 269-275. DOI: 10.1186/s41601-017-0059-8.
- [7] YANG J, STENZEL J. Application of two-dimensional support vector machine in short-term load forecasting[C] // 2005 IEEE Russia Power Tech, June 27-30, 2005, St. Petersburg, Russia: 1-4.
- [8] 詹仁俊. 基于 K-means 聚类的小波支持向量机配电网短期负荷预测及应用[J]. 供用电, 2019, 36(4): 64-70.
ZHAN Renjun. Short-term load forecasting and application for distribution network of wavelet support vector machine based on K-means clustering[J]. Distribution & Utilization, 2019, 36(4): 64-70.
- [9] 方八零, 李龙, 赵家铸, 等. 动态相似与静态相似相结合的短期负荷预测方法[J]. 电力系统保护与控制, 2018, 46(15): 29-35.
FANG Baling, LI Long, ZHAO Jiazhu, et al. Short term load forecasting based on the combination of dynamic similarity and static similarity[J]. Power System Protection and Control, 2018, 46(15): 29-35.
- [10] 刘翊枫, 周国鹏, 刘昕, 等. 基于智能相似日识别及偏差校正的短期负荷预测方法[J]. 电力系统保护与控制, 2019, 47(12): 138-145.
LIU Yifeng, ZHOU Guopeng, LIU Xin, et al. A short-term load forecasting method based on intelligent similar day recognition and deviation correction[J]. Power System Protection and Control, 2019, 47(12): 138-145.
- [11] LIAO X, CAO N, LI M, et al. Research on short-term load forecasting using XGBoost based on similar days[C] // 2019 IEEE International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS), 2019: 675-678.
- [12] SUN H, WANG W. Electric short-term load forecasting using artificial neural networks and fuzzy expert system[C] // Proceedings of the 2011 International Conference on Informatics, Cybernetics, and Computer Engineering (ICCE2011), November 19-20, 2011, Melbourne, Australia: 699-707.
- [13] 孙为民, 郝智勇, 赵星宇, 等. 县域电网负荷特性分析与短期负荷预测研究[J]. 华北电力技术, 2017(5): 27-31.
SUN Weimin, HAO Zhiyong, ZHAO Xingyu, et al. Load characteristics analysis and short term load forecasting research of a county power grid[J]. North China Electric Power, 2017(5): 27-31.
- [14] 刘晶. 基于相似日和支撑向量的短期负荷预测研究[D]. 广州: 华南理工大学, 2010.
LIU Jing. Short-term power load forecasting based on similar day and support vector machine[D]. Guangzhou: South China University of Technology, 2010.

- [15] 彭建春, 赵凯, 石峰, 等. 基于模式识别的自适应短期负荷预测系统[J]. 电力自动化设备, 2001, 21(4): 29-32.
PENG Jianchun, ZHAO Kai, SHI Feng, et al. A pattern-recognition-based adaptive system for short term load forecasting[J]. Electric Power Automation Equipment, 2001, 21(4): 29-32.
- [16] 林辉, 刘晶, 郝志峰, 等. 基于相似日负荷修正的节假日短期负荷预测[J]. 电力系统保护与控制, 2010, 38(7): 47-51.
LIN Hui, LIU Jing, HAO Zhifeng, et al. Short-term load forecasting for holidays based on the similar days' load modification[J]. Power System Protection and Control, 2010, 38(7): 47-51.
- [17] 李啸骢, 李春涛, 从兰美, 等. 基于动态权值相似日选取算法的短期负荷预测[J]. 电力系统保护与控制, 2017, 45(6): 1-8.
LI Xiacong, LI Chuntao, CONG Lanmei, et al. Short-term load forecasting based on dynamic weight similar day selection algorithm[J]. Power System Protection and Control, 2017, 45(6): 1-8.
- [18] 黎灿兵, 李晓辉, 赵瑞, 等. 电力短期负荷预测相似日选取算法[J]. 电力系统自动化, 2008, 32(9): 69-73.
LI Canbing, LI Xiaohui, ZHAO Rui, et al. A novel algorithm of selecting similar days for short-term power load forecasting[J]. Automation of Electric Power Systems, 2008, 32(9): 69-73.
- [19] 吴小文, 李擎. 果蝇算法和 5 种群智能算法的寻优性能研究[J]. 火力与指挥控制, 2013, 38(4): 17-20.
WU Xiaowen, LI Qing. Research of optimizing performance of fruit fly optimization algorithm and five kinds of intelligent algorithm[J]. Fire Control & Command Control, 2013, 38(4): 17-20.
- [20] SHAN D, CAO G, DONG H, et al. LGMS-FOA: an improved fruit fly optimization algorithm for solving optimization problems[J]. Mathematical Problems in Engineering, 2013, 2013.
- [21] 梁妮晓. 基于改进果蝇算法优化支持向量机的短期负荷预测[D]. 南宁: 广西大学, 2014.
LIANG Nixiao. Short-term load forecasting based on modified fruit fly algorithm and support vector machine[D]. Nanning: Guangxi University, 2014.
- [22] 王念, 张靖, 李博文, 等. 基于加权果蝇优化算法的多区域频率协同控制[J]. 电力系统保护与控制, 2020, 48(11): 102-109.
WANG Nian, ZHANG Jing, LI Bowen, et al. Load frequency control of a multi-area power system based on weighting fruit fly optimization algorithm[J]. Power System Protection and Control, 2020, 48(11): 102-109.
- [23] 吕何, 孔政敏, 张成刚. 基于混合优化随机森林回归的短期电力负荷预测[J]. 武汉大学学报: 工学版, 2020, 53(8): 704-711.
Lǚ He, KONG Zhengmin, ZHANG Chenggang. Short-term load forecasting based on hybrid optimized random forest regression[J]. Engineering Journal of Wuhan University, 2020, 53(8): 704-711.
- [24] MENG T, PAN Q K. An improved fruit fly optimization algorithm for solving the multidimensional knapsack problem[J]. Applied Soft Computing, 2017, 50: 79-93.

收稿日期: 2020-09-18; 修回日期: 2020-12-14

作者简介:

陈弘川(1996—), 女, 硕士, 主要研究方向为电力系统优化调度; E-mail: chenhongchuan@sjtu.edu.cn

蔡旭(1964—), 男, 通信作者, 博士, 教授, 主要研究方向为新能源接入装备及其并网技术。E-mail: xucai@sjtu.edu.cn

(编辑 葛艳娜)